

โครงการฝึกอบรม

หลักสูตร “การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานวิศวกรรมชลประทาน”

โดย สถาบันพัฒนาการชลประทาน สำนักวิจัยและพัฒนา

๑. หลักการและเหตุผล

การประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Networks, ANNs) ซึ่งจัดเป็นประเภท Black Box Model โดยอาศัยความสัมพันธ์ของ Input กับ Output เป็นหลัก ซึ่งแบบจำลอง ANNs นั้นจะมีหลาย Algorithm ให้เลือกใช้งาน แต่ที่นิยมใช้กันอย่างแพร่หลายนั้นจะเป็นชนิด Backpropagation Algorithm หรือการคำนวณย้อนกลับเพื่อหาความสัมพันธ์ของข้อมูลที่ดีที่สุด การประยุกต์ใช้ ANNs จะมีข้อดี คือ โครงสร้างของโมเดลจะใช้งานง่าย สะดวก และรวดเร็ว โดยไม่ได้เน้นข้อมูลทางด้านกายภาพมากนัก นอกจากนี้ ANNs ยังสามารถนำไปประยุกต์ใช้ได้หลายแขนง แต่ในที่นี้จะเน้นถึงการนำมาประยุกต์ใช้ในงานด้านการชลประทานและทรัพยากรแหล่งน้ำ เป็นหลัก อาทิเช่น การพยากรณ์ปริมาณน้ำไหลลงอ่างเก็บน้ำรายวัน หรือการพยากรณ์ปริมาณน้ำท่ารายวันที่สถานีต่าง ๆ เป็นต้น

๒. วัตถุประสงค์

๒.๑ เพื่อให้ผู้เข้ารับการอบรมมีความรู้เบื้องต้นเกี่ยวกับแบบจำลองคณิตศาสตร์ที่ใช้งานทางด้านชลประทานและทรัพยากรน้ำในปัจจุบัน

๒.๒ เพื่อให้ผู้เข้ารับการอบรมมีความรู้ ความเข้าใจ และสามารถประยุกต์ใช้แบบจำลอง ANNs สำหรับงานชลประทาน ได้แก่ การพยากรณ์ปริมาณน้ำไหลลงอ่างเก็บน้ำ และการพยากรณ์ปริมาณน้ำท่ารายวันที่สถานีน้ำท่าต่าง ๆ

๒.๓ เพื่อให้ผู้เข้ารับการฝึกอบรมได้มีโอกาสนพบปะ สร้างความคุ้นเคยและแลกเปลี่ยนความรู้ ข้อคิดเห็นซึ่งกันและกัน อันจะก่อให้เกิดประโยชน์ต่อการปฏิบัติงานให้มีประสิทธิภาพมากยิ่งขึ้น

๓. หัวข้อการฝึกอบรม

๓.๑ การพยากรณ์ด้วยเทคนิคต่างๆ / การวัดความแม่นยำของการพยากรณ์ จำนวน ๓ ชั่วโมง

๓.๒ ทฤษฎีเบื้องต้นของ ANNs จำนวน ๓ ชั่วโมง

๓.๓ การประยุกต์ใช้ ANNs ในการพยากรณ์ จำนวน ๓ ชั่วโมง

๓.๔ ทดลองใช้แบบจำลอง ANNs พยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำ จำนวน ๖ ชั่วโมง

๓.๕ วิเคราะห์ผล/ข้อจำกัด/เทคนิคในการปรับค่าต่างๆ ในแบบจำลอง ANNs จำนวน ๓ ชั่วโมง

๔. ประโยชน์ที่คาดว่าจะได้รับ

๔.๑ ผู้ผ่านการฝึกอบรมสามารถนำความรู้ที่ได้รับไปประยุกต์ใช้ ANNs ในการปฏิบัติงานด้านต่างๆ ที่เกี่ยวข้อง

๔.๒ การพยากรณ์น้ำฝน น้ำท่า ปริมาณน้ำไหลเข้าอ่างเก็บน้ำมีความแม่นยำมากยิ่งขึ้น ช่วยเพิ่มประสิทธิภาพในการบริหารจัดการทรัพยากรน้ำ

๕. คุณสมบัติของผู้เข้ารับการฝึกอบรม

- ๕.๑ เป็นข้าราชการกรมชลประทาน
- ๕.๒ มีพื้นฐานความรู้ทางด้านคอมพิวเตอร์เป็นอย่างดี
- ๕.๓ เป็นผู้สำเร็จการศึกษาในระดับปริญญาตรีทางด้านวิศวกรรม หรือ มีพื้นฐานประกาศนียบัตรการชลประทาน
- ๕.๔ สามารถเข้ารับการฝึกอบรมได้อย่างสม่ำเสมอตลอดหลักสูตร

๖. จำนวนผู้เข้ารับการฝึกอบรม

ผู้เข้ารับการฝึกอบรมรุ่นละ ๓๐ คน

๗. ระยะเวลาในการฝึกอบรม

จำนวน ๑ รุ่น รุ่นละ ๓ วันทำการ ระหว่างวันที่ ๒๓ – ๒๕ กุมภาพันธ์ พ.ศ. ๒๕๕๔

๘. สถานที่ในการฝึกอบรม

สถานที่ ห้องคอมพิวเตอร์ อาคารอำนวยการ สถาบันพัฒนาการชลประทาน

๙. เทคนิคการฝึกอบรม

การบรรยาย การสาธิต และการฝึกปฏิบัติ

๑๐. วิทยากรในการฝึกอบรม

นายคมสันต์ ไชโย วิศวกรชลประทานชำนาญการ สถาบันพัฒนาการชลประทาน

๑๑. การประเมินผลโครงการฝึกอบรม

- ๑๑.๑ ประเมินผลสัมฤทธิ์โครงการฝึกอบรม ดังนี้
 - ๑๑.๑.๑ จำนวนผู้เข้ารับการฝึกอบรมจริง ต้องไม่ต่ำกว่า ๘๐% ของจำนวนผู้เข้ารับการฝึกอบรมตามเป้าหมายโครงการที่กำหนดไว้
 - ๑๑.๑.๒ ร้อยละของผู้เข้ารับการฝึกอบรมผ่านเกณฑ์การประเมินในระดับดี โดยมีเกณฑ์การประเมินจำแนก ดังนี้
 - ประเมินความรู้ ความเข้าใจ โดยทดสอบก่อน – หลังการฝึกอบรม
 - ประเมินพฤติกรรมการเรียนรู้ และการฝึกปฏิบัติของผู้เข้ารับการฝึกอบรม
 - ประเมินความคุ้มค่าด้านการประหยัดค่าใช้จ่ายของโครงการฝึกอบรมเปรียบเทียบกับงบประมาณที่ได้รับการจัดสรร
- ๑๑.๒ ประเมินความเหมาะสมของกระบวนการฝึกอบรม โดยใช้แบบสอบถาม

๑๒. เกณฑ์ชี้วัดผลสำเร็จของโครงการ

ผลผลิต (จากการประเมินผลโครงการ)

- ๑๒.๑ จำนวนผู้เข้ารับการฝึกอบรมจริง ต้องไม่ต่ำกว่า ๘๐% ของจำนวนผู้เข้ารับการฝึกอบรมตามเป้าหมายโครงการที่กำหนดไว้

- ๑๒.๒ ร้อยละ ๕๐ ของผู้เข้ารับการฝึกอบรมผ่านเกณฑ์การประเมินในระดับดี
- ๑๒.๓ ร้อยละ ๕๐ ของผู้เข้ารับการฝึกอบรมมีการวางแผนการนำความรู้จากการฝึกอบรมไปประยุกต์ใช้ในการปฏิบัติงาน
- ๑๒.๔ จำนวนค่าใช้จ่ายในการดำเนินโครงการ ต่ำกว่างบประมาณที่ได้รับการจัดสรร ไม่น้อยกว่า ร้อย ๒

๑๓. การรับรองผลผู้ผ่านการฝึกอบรม

ผู้ที่ผ่านการฝึกอบรมจะได้รับประกาศนียบัตรของสถาบันพัฒนาการชลประทาน โดยผู้ที่เข้ารับการฝึกอบรมต้องมีเวลาเข้ารับการฝึกอบรมไม่ต่ำกว่า ๘๐% ของระยะเวลาตลอดหลักสูตร โดยจะมีเกณฑ์การวัดผล ดังนี้

๑๓.๑ ไม่ผ่าน เนื่องจากระยะเวลาการเข้ารับการฝึกอบรมต่ำกว่าเกณฑ์ที่กำหนด (หากไม่ผ่านจะไม่ได้รับประกาศนียบัตร)

๑๓.๒ ผ่าน มี ๓ ระดับ

- ผ่าน
- ผ่าน ในระดับ ดี
- ผ่าน ในระดับ ดีมาก

ทั้งนี้ ผลการประเมินของผู้เข้ารับการฝึกอบรมทุกท่าน สถาบันฯจะนำเสนอให้ผู้บังคับบัญชาในภายหลัง

๑๔. ค่าใช้จ่ายการฝึกอบรม

๑๔.๑ ค่าใช้จ่ายในการดำเนินการฝึกอบรมใช้งบประมาณของสถาบันพัฒนาการชลประทาน

๑๔.๒ ค่าใช้จ่ายของผู้เข้ารับการฝึกอบรมให้ใช้งบประมาณจากต้นสังกัดของผู้เข้ารับการฝึกอบรม

๑๕. ที่ปรึกษาโครงการ

๑๕.๑ รองอธิบดีฝ่ายวิชาการ

๑๕.๒ รองอธิบดีฝ่ายบำรุงรักษา

๑๕.๓ ผู้อำนวยการสำนักวิจัยและพัฒนา

๑๕.๔ ผู้อำนวยการสำนักพัฒนาโครงสร้างและระบบบริหารงานบุคคล

๑๕.๕ ผู้เชี่ยวชาญด้านวิศวกรรมชลประทาน (ด้านบริหารจัดการน้ำ)

๑๕.๖ ที่ปรึกษาผู้ทรงคุณวุฒิประจำสถาบันพัฒนาการชลประทาน

๑๖. ผู้รับผิดชอบโครงการ

๑๖.๑ นายวัชร เสือดี

๑๖.๒ นายดิเรก เขียวมณีวงศ์

๑๖.๓ นายไพศาล พงศ์นรินทร์

ผู้อำนวยการสถาบันพัฒนาการชลประทาน

วิศวกรชลประทานชำนาญการพิเศษ

สถาบันพัฒนาการชลประทาน

วิศวกรชลประทานชำนาญการพิเศษ

สถาบันพัฒนาการชลประทาน

๑๖.๔ นายบัญชา เรืองศิลป์ประเสริฐ วิศวกรชลประทานชำนาญการพิเศษ
สถาบันพัฒนาการชลประทาน

๑๗. ผู้ประสานงานและดำเนินงานโครงการ

๑๗.๑ นายปกรณ์ สุตสุนทร	วิศวกรชลประทานชำนาญการพิเศษ สถาบันพัฒนาการชลประทาน
๑๗.๒ นายณัฐพล วุฒิจันทร์	วิศวกรชลประทานชำนาญการ สถาบันพัฒนาการชลประทาน
๑๗.๓ ดร.วิชญ์ ศรีวงษา	นายช่างชลประทานชำนาญงาน สถาบันพัฒนาการชลประทาน
๑๗.๔ นายสมยศ พูลธนะสาร	นักวิชาการแผนที่ภาพถ่ายชำนาญการ สถาบันพัฒนาการชลประทาน
๑๗.๕ นางเฉลิมศรี ดวงมณี	บรรณารักษ์ชำนาญการ สถาบันพัฒนาการชลประทาน
๑๗.๖ นายคมสันต์ ไชโย	วิศวกรชลประทานชำนาญการ สถาบันพัฒนาการชลประทาน
๑๗.๗ นางเรียม ทองย้อย	เจ้าพนักงานธุรการชำนาญงาน สถาบันพัฒนาการชลประทาน
๑๗.๘ นายกรตสุวรรณ โพธิ์สุวรรณ	วิศวกรชลประทานชำนาญการ สถาบันพัฒนาการชลประทาน
๑๗.๙ นายธเนศ อักษร	วิศวกรชลประทานชำนาญการ สถาบันพัฒนาการชลประทาน
๑๗.๑๐ นายรส สุบสการ	วิศวกรชลประทานปฏิบัติการ สถาบันพัฒนาการชลประทาน

๑๘. ติดต่อสอบถามข้อมูล

๑๘.๑ นายคมสันต์ ไชโย	วิศวกรชลประทานชำนาญการ
๑๘.๒ น.ส.กวินตรา ฤทธิเจริญ	เจ้าหน้าที่ประสานงานฝึกอบรม

สถาบันพัฒนาการชลประทาน กรมชลประทาน ปากเกร็ด นนทบุรี ๑๑๑๒๐ โทร. ๐-๒๕๘๔-
๐๓๗๘-๙ ต่อ ๑๐๙ E-mail: hathairat@irricollege.ac.th

บทที่ 1

ทิศทางการฝึกอบรมตามแผนยุทธศาสตร์ของกรมชลประทาน

1.1 สถานการณ์ในปัจจุบัน

1.1.1 สภาพอุตุ-อุทกวิทยา

ประเทศไทยตั้งอยู่ในภูมิภาคเอเชียตะวันออกเฉียงใต้ ได้รับอิทธิพลจากลมมรสุมและพายุจร สามารถจำแนกฤดูกาลได้เป็น 3 ฤดู โดยฤดูฝน เริ่มตั้งแต่เดือนมิถุนายน ถึงเดือนกันยายน ฤดูหนาว เริ่มตั้งแต่เดือนตุลาคมถึงเดือนมกราคม และ ฤดูร้อนเริ่มตั้งแต่เดือนกุมภาพันธ์ถึงเดือนพฤษภาคม อุณหภูมิ ปริมาณฝนเฉลี่ยผันแปรตามฤดูกาล และในแต่ละปีทำให้ประสบปัญหาอุทกภัยและภัยแล้งอยู่เป็นประจำ เนื่องจากอยู่ในเขตอิทธิพลของลมมรสุม และลมพายุจร ทำให้สภาพทางด้านอุทกวิทยามีความผันแปรสูง จึงประสบปัญหาอุทกภัยในช่วงฤดูน้ำหลาก และปัญหาภัยแล้งในช่วงฤดูแล้งอยู่เสมอ

ประเทศไทยมีพื้นที่ประมาณ 512,000 ตร.กม. (320 ล้านไร่) โดยลักษณะทางอุทกวิทยา แบ่งพื้นที่ตามกลุ่มลุ่มน้ำ 9 กลุ่ม แม่น้ำสายหลักได้ 25 ลุ่มน้ำหลัก และ 254 ลุ่มน้ำย่อย ได้รับน้ำจากฝนที่ตกกระจายทั่วประเทศระหว่าง 800-4,400 มม. เฉลี่ยทั้งปีประมาณ 1,424 มม. เป็นปริมาณน้ำฝนรวมในแต่ละปี 719,500 ล้าน ลบ.ม. น้ำฝนประมาณ 506,000 ล้าน ลบ.ม./ปี (ร้อยละ 70) ได้ระเหยสู่บรรยากาศ และไหลซึมลงดิน ป่าไม้และพืชในฤดูฝนนำไปใช้ในการเจริญเติบโต และขังตามแอ่งหรือหนองบึงธรรมชาติต่างๆ ที่เหลือประมาณ 213,500 ล้าน ลบ.ม./ปี (ร้อยละ 30) เป็นน้ำทำซึ่งไหลตามแม่น้ำลำธาร และลำห้วยต่างๆ แล้วไหลลงสู่ทะเล ซึ่งถือเป็นปริมาณน้ำผิวดินที่มีศักยภาพในการนำมาใช้พัฒนาได้ และปริมาณน้ำทำนี้แบ่งตามสภาพน้ำที่ไหลลงสู่ทะเลได้เป็น 3 ส่วน คือ ไหลลงสู่อ่าวไทยจำนวนมากที่สุด คือ ร้อยละ 60 ไหลลงแม่น้ำโขงสู่ทะเลจีนใต้ ร้อยละ 30 และไหลลงสู่ทะเลอันดามันร้อยละ 10

1.1.2 น้ำท่าเฉลี่ย

ปริมาณน้ำท่าข้างต้น คิดเป็นน้ำท่าเฉลี่ยต่อจำนวนประชากร 3,285 ลบ.ม./คน/ปี (จำนวนประชากร 65 ล้านคน) เป็นน้ำท่าในฤดูฝนจำนวน 2,825 ลบ.ม./คน/ปี (ร้อยละ 86) และในฤดูแล้ง 60 ลบ.ม./คน/ปี (ร้อยละ 14) ดังนั้น ในภาพรวมของประเทศ ปริมาณน้ำท่าเฉลี่ยต่อคนต่อปียังอยู่ในระดับสูง เมื่อเทียบกับข้อสรุปของนักอุทกวิทยานานาชาติที่ว่าประเทศใดมีปริมาณน้ำหมุนเวียนมากกว่า 1,700 ลบ.ม./คน/ปี ถือว่าไม่มีปัญหาการขาดแคลนน้ำอย่างแท้จริง

1.1.3 ปริมาณการเก็บกักน้ำ

ปัจจุบันแหล่งเก็บกักน้ำทั้งอ่างเก็บน้ำขนาดใหญ่ และขนาดกลาง ที่สร้างโดยกรมชลประทาน และการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย มีความจุทั้งสิ้น ประมาณ 72,645 ล้าน ลบ.ม. คิด

เป็นร้อยละ 34 ของปริมาณน้ำท่าทั้งหมด โดยเป็นความจุที่ใช้งานได้ประมาณ 51,241 ล้าน ลบ.ม. ทั้งนี้ เพื่อเหลือน้ำส่วนหนึ่ง ไว้สำหรับการรักษาสภาพเขื่อน (Dead Storage) ประมาณ 21,404 ล้าน ลบ.ม.

1.1.4 การใช้ที่ดินภาคการเกษตร

ประเทศไทยมีพื้นที่ทั้งหมด 320 ล้านไร่ การใช้ที่ดินเพื่อการเกษตรมีการขยายตัวอย่างรวดเร็ว ในช่วงแผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ ฉบับที่ 1-6 (2504-2533) จากในช่วงปี 2493 ที่มีการใช้พื้นที่เพื่อการเพาะปลูกเพียง 32.1 ล้านไร่ หรือ ร้อยละ 10 ของพื้นที่ทั่วทั้งประเทศ โดยส่วนใหญ่กว่าร้อยละ 90 เป็นการทำนา แต่ ในปี 2531 พื้นที่การเกษตรของประเทศไทยได้ขยายเป็นมากกว่า 120 ล้านไร่ โดยอัตราขยายตัวของพื้นที่การเกษตรเกิดจากการเปลี่ยนแปลงสภาพพื้นที่ป่าไม้เป็นพื้นที่เพาะปลูก ในปัจจุบันประเทศไทยมีพื้นที่ทำการเกษตรทั้งสิ้นประมาณ 140 ล้านไร่ คิดเป็นเนื้อที่ถือครองทางการเกษตรเฉลี่ยต่อครัวเรือน 22.48 ไร่ การเกษตรที่สำคัญได้แก่การทำนา การปลูกพืชไร่ และการปลูกไม้ผลไม้อื่นต้น โดยมีสัดส่วนการใช้ที่ดินประมาณร้อยละ 49 21 และ 21 ตามลำดับ

1.1.5 การพัฒนาการชลประทาน

การพัฒนาการชลประทานในอดีตตั้งแต่สมัยรัชกาลที่ 5 ได้มุ่งเน้นการกระจายน้ำโดยการขุดคลองเชื่อมโยงน้ำระหว่างแม่น้ำสายหลักในบริเวณที่ราบลุ่มภาคกลางของประเทศ ต่อมาในช่วงก่อนปี 2500 ได้มีการพัฒนาอาคารทดน้ำตามแม่น้ำสายหลักเพื่อเพิ่มขีดความสามารถในการผันน้ำเข้าสู่ระบบคลอง ในบริเวณที่ราบลุ่มภาคเหนือ ตอนบน และภาคกลาง ทำให้การเกษตรชลประทานได้ขยายตัวขึ้นอย่างมาก อย่างไรก็ตาม การเกษตรชลประทานในยุคนั้น ยังคงมีขีดจำกัด เนื่องจากยังไม่มีการพัฒนาแหล่งเก็บกักน้ำขนาดใหญ่ที่จะรองรับปริมาณน้ำหลากจากพื้นที่ตอนบน ทำให้ยังคงประสบปัญหาอุทกภัยและภัยแล้งตามฤดูกาล

ในต้นศตวรรษ 2500 ได้มีการก่อสร้างแหล่งเก็บกักน้ำขนาดใหญ่ ได้แก่ เขื่อนภูมิพล และเขื่อนสิริกิติ์ ทำให้ปัญหาอุทกภัยบรรเทาลงมากและมีปริมาณน้ำสำรองในอ่างเก็บกักน้ำสำหรับจัดสรรเพื่อการเกษตรในฤดูแล้ง ทำให้สามารถขยายพื้นที่เกษตรชลประทานและการเพาะปลูกในฤดูแล้งได้อย่างรวดเร็ว ในระยะต่อมาได้มีการกระจาย การพัฒนาแหล่งน้ำและการเกษตรชลประทานขนาดใหญ่และขนาดกลางออกไปทั้ง 25 กลุ่มน้ำทั่วประเทศ ส่งผลให้เศรษฐกิจของประเทศเติบโตขึ้นอย่างรวดเร็ว นอกจากนี้ ยังมีการดำเนินงานเพื่อแก้ไขปัญหาการขาดแคลนน้ำระดับท้องถิ่น โดยการก่อสร้างแหล่งน้ำขนาดเล็กกระจายตามพื้นที่ชุมชนในชนบท

ปัจจุบัน (ณ 30 กันยายน 2549) กรมชลประทานได้มีการพัฒนาโครงการชลประทานขนาดใหญ่จำนวน 85 แห่ง ปริมาตรความจุรวม 7,548.80 ล้าน ลบ.ม. มีพื้นที่ชลประทาน 17,094,997 ไร่ โครงการชลประทานขนาดกลาง จำนวน 703 แห่ง ปริมาตรความจุรวม 3,893.02 ล้าน ลบ.ม. มีพื้นที่ชลประทาน 6,537,070 ไร่ และโครงการชลประทานขนาดเล็ก 11,567 แห่ง ปริมาตรความจุรวม 1,672.86 ล้าน ลบ.ม.

มีพื้นที่ประทาน 568,518 ล้านไร่ พื้นที่รับประโยชน์ 9,270,540 ไร่ นอกจากนี้ยังมีโครงการสูบน้ำด้วย
กระแสไฟฟ้า จำนวน 2,129 โครงการ พื้นที่ชลประทาน 3,787,777 ล้านไร่ พื้นที่รับประโยชน์ 313,314
ไร่ รวมพื้นที่ชลประทานทั้งหมด 27,988,362 ไร่ พื้นที่รับประโยชน์ 9,583,854 ไร่ และมีอ่างเก็บน้ำ
ขนาดใหญ่ ที่ดูแลโดยการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย จำนวน 10 แห่ง ปริมาตรความจุรวม
61,203.48 ล้าน ลบ.ม. รวมความจุที่สามารถเก็บกักได้ของอ่างเก็บน้ำขนาดใหญ่และขนาดกลาง 72,645
ล้าน ลบ.ม. (ที่มา : รายงานข้อมูลสารสนเทศโครงการชลประทาน ปีงบประมาณ พ.ศ. 2549) โดยที่ภาค
กลางเป็นภาคที่มีการพัฒนาพื้นที่ชลประทานได้มากที่สุด คือ 10,950,373 ไร่ คิดเป็น ร้อยละ 43.5 ของ
พื้นที่ทำการเกษตรที่มีอยู่ 25,166,801 ล้านไร่ ภาคเหนือพัฒนาพื้นที่ชลประทานได้ 5,060,260 ไร่ คิด
เป็นร้อยละ 21.9 ของพื้นที่ทำการเกษตรที่มีอยู่ 23,069,487 ไร่ ภาคตะวันออกเฉียงเหนือพัฒนาพื้นที่ชลประทาน
ได้ 2,536,507 ไร่ คิดเป็นร้อยละ 21.8 ของพื้นที่ทำการเกษตรที่มีอยู่ 11,615,835 ไร่ ภาคใต้พัฒนาพื้นที่
ชลประทานได้ 3,278,488 ไร่ คิดเป็นร้อยละ 15.6 ของพื้นที่ทำการเกษตรที่มีอยู่ 20,951,105 ไร่ และ
ภาคตะวันออกเฉียงเหนือพัฒนาพื้นที่ชลประทานได้ 6,162,734 ไร่ คิดเป็นร้อยละ 10.4 ของพื้นที่ทำ
การเกษตรที่มีอยู่ 58,996,891 ไร่

1.2 กรมชลประทาน

1.2.1 วิสัยทัศน์

“น้ำสมบูรณ์ สนับสนุนการผลิต เสริมสร้างคุณภาพชีวิต เศรษฐกิจมั่นคง “

1.2.2 พันธกิจ

- 1) พัฒนาแหล่งน้ำตามศักยภาพของกลุ่มน้ำให้สมดุล
- 2) บริหารจัดการน้ำอย่างมีประสิทธิภาพ ทั้งถึง เป็นธรรม และยั่งยืน
- 3) เสริมสร้างการมีส่วนร่วมในกระบวนการพัฒนาและบริหารจัดการน้ำทุกระดับอย่างบูรณาการ
- 4) ดำเนินการป้องกันและบรรเทาภัยอันเกิดจากน้ำ
- 5) สนับสนุนการรักษาพื้นที่ทำการเกษตรในเขตชลประทานเพื่อการผลิตให้อยู่ในจำนวนที่เหมาะสม

1.2.3 ประเด็นยุทธศาสตร์

- 1) การพัฒนาแหล่งน้ำ
- 2) การบริหารจัดการน้ำ
- 3) การป้องกันและบรรเทาภัยอันเกิดจากน้ำ
- 4) การรักษาพื้นที่ทำการเกษตรในเขตชลประทาน

1.2.4 เป้าประสงค์

กรมชลประทาน ได้กำหนดเป้าประสงค์ตามกรอบการประเมินผลการปฏิบัติงาน 4 ด้าน คือ ด้านประสิทธิผลตามพันธกิจ ด้านคุณภาพการให้บริการ ด้านประสิทธิภาพ การปฏิบัติราชการ และด้านการพัฒนาองค์กร มีจำนวน 20 เป้าประสงค์ คือ

1) ด้านประสิทธิผลตามพันธกิจ

- (1) มีปริมาณน้ำเก็บกักและพื้นที่ชลประทานเพิ่มขึ้น
- (2) ทุกภาคส่วนได้รับน้ำอย่างทั่วถึง และเป็นธรรม
- (3) ความสูญเสียอันเนื่องมาจากภัยอันเกิดจากน้ำลดลง
- (4) มีจำนวนพื้นที่การเกษตรในเขตชลประทานที่เหมาะสม

2) ด้านคุณภาพการให้บริการ

- (1) อาคารชลประทานอยู่ในสภาพพร้อมใช้งาน
- (2) ผู้ใช้น้ำได้รับน้ำตามปริมาณ และเวลาที่ต้องการ
- (3) พื้นที่ได้รับความเสียหายจากภัยอันเกิดจากน้ำมีจำนวนลดลง
- (4) คุณภาพน้ำได้เกณฑ์มาตรฐาน

3) ด้านประสิทธิภาพของการปฏิบัติราชการ

- (1) การก่อสร้าง ซ่อมแซม และปรับปรุงแล้วเสร็จตามแผนงาน
- (2) การเตรียมความพร้อมก่อนการก่อสร้างเป็นไปตามแผนงาน
- (3) ประชาชน ชุมชน และหน่วยงานที่เกี่ยวข้องมีส่วนร่วม
- (4) มีการประชาสัมพันธ์อย่างต่อเนื่องและทั่วถึง
- (5) มีการวางแผน และการดำเนินการบริหารจัดการน้ำที่ดี
- (6) มีระบบเฝ้าระวังเตือนภัย และการพยากรณ์สถานการณ์น้ำล่วงหน้า

4) งานด้านการพัฒนาองค์กร

- (1) ระบบการบริหารงานมีประสิทธิภาพ
- (2) บุคลากรมีสมรรถนะ และขวัญกำลังใจในการทำงาน
- (3) มีระบบฐานข้อมูล และเทคโนโลยีสารสนเทศที่เหมาะสม
- (4) มีผลการวิจัยและพัฒนา สนับสนุนการดำเนินงาน
- (5) มีอุปกรณ์ เครื่องจักรเครื่องมือ และสิ่งอำนวยความสะดวกที่เพียงพอ
- (6) มีระเบียบและกฎหมายที่ทันสมัย


1.2.5 แผนที่ยุทธศาสตร์

ประเด็นยุทธศาสตร์ที่ 1 การพัฒนาแหล่งน้ำ

ประเด็นยุทธศาสตร์ที่ 2 การบริหารจัดการน้ำ

ประเด็นยุทธศาสตร์ที่ 3 การป้องกันและบรรเทาภัยอันเกิดจากน้ำ

ประเด็นยุทธศาสตร์ที่ 4 การรักษาพื้นที่ทำการเกษตรในเขตชลประทาน




ที่มา : แผนยุทธศาสตร์กรมชลประทาน (ประกาศใช้ 1 ตุลาคม 2550)

บทที่ 2

ทฤษฎี ANNs

โครงข่ายประสาทเทียม เป็นแนวคิดที่ถูกออกแบบให้ทำงานเช่นเดียวกับสมองมนุษย์ ซึ่งประกอบไปด้วยหน่วยประมวลผล (Processing Elements) ซึ่งมีเซลล์หลายๆ ตัวที่ทำหน้าที่คล้ายกับเซลล์สมองของมนุษย์ โดยที่แต่ละเซลล์จะโยงใยติดต่อกันโดยส่งสัญญาณออกเป็นเอาต์พุต (Output) ผ่านส่วนที่เรียกว่า ซินแนปส์ (Synapses) กลายมาเป็นอินพุต (Input) ของส่วนที่เรียกว่า เดนไดรต์ (Dendrites) และเมื่อผ่านกระบวนการประมวลผลจะได้เอาต์พุตออกมาในส่วนที่เรียกว่า แอ็กซอน (Axon) ในแต่ละเซลล์จะรับรู้ข้อมูลจากหลายทาง แล้วส่งต่อไปยังเซลล์อื่นๆ โดยใช้หลักการ Synaptic Strength ของการเชื่อมโยงเซลล์สมอง ดังแสดงในรูปที่ 2-1



รูปที่ 2-1 การจำลองโครงข่ายประสาทเทียม

ส่วนวิธีการประมวลผลภายในโดยเซลล์ประสาทแต่ละเซลล์จะมีจุดเชื่อมโยงระหว่างการทำงานเป็น 2 ลักษณะ คือ ลักษณะการกระตุ้น (Excitatory) เป็นการทำให้สัญญาณที่ส่งผ่านเข้ามามีความถี่สูงขึ้น และลักษณะการยับยั้ง (Inhibitory) เป็นการทำให้สัญญาณที่ส่งผ่านเข้ามามีความถี่ลดลง ซึ่งแบบจำลองของ ANN จะมีอัตราขยายหรือหดได้เมื่อถูกกำหนดด้วยค่าถ่วงน้ำหนัก (Weights) สำหรับความสัมพันธ์ระหว่างเซลล์ประสาทกับเซลล์ประสาทเทียม แสดงไว้ในตารางที่ 2-1

ตารางที่ 2-1 ความสัมพันธ์ระหว่างเซลล์ประสาทกับเซลล์ประสาทเทียม

ลำดับ	เซลล์ประสาท	เซลล์ประสาทเทียม
1	ตัวเซลล์ (Cell Body)	ยูนิต (Unit)
2	เดนไดรต์ (Dendrites)	ตัวแปรอินพุต (Input)
3	แอกซอน (Axon)	ตัวแปรเอาต์พุต (Output)
4	ไซแนปส์ (Synapse)	ค่าถ่วงน้ำหนัก (Weight)
5	ความเร็วในการทำงานช้า	ความเร็วในการทำงานสูง
6	มีเซลล์จำนวนมาก (ประมาณ 10^9 ยูนิต)	มีเซลล์จำนวนน้อยกว่า (เป็นหลักร้อย)

โดยทั่วไปในสมองของมนุษย์จะมีเซลล์ประมาณ 10^9 ถึง 10^{12} เซลล์ โดยที่แต่ละเซลล์สามารถเก็บหน่วยความจำได้มากมาย โดยเฉลี่ยสมองมนุษย์มีน้ำหนัก 1.5 กก. ซึ่งประกอบไปด้วยเซลล์เล็กๆ ที่มีน้ำหนักน้อยกว่า 1.5×10^{-9} กรัม

โครงข่ายประสาทเทียมเป็นแบบจำลองการทำงานของระบบประสาทส่วนกลางที่มีโครงสร้างเป็นลักษณะของโครงข่ายเชื่อมโยงกันระหว่างหน่วย ซึ่งสามารถที่จะรับรู้ข้อมูลและปรับตัวเข้ากับสถานการณ์หรือสิ่งแวดล้อมที่กำลังเผชิญอยู่ นักวิจัยหลายท่านเชื่อว่า แบบจำลองโครงข่ายประสาทเทียมเป็นเครื่องมือชนิดหนึ่งที่ใช้ในการสร้างระบบคอมพิวเตอร์อัจฉริยะ (Intelligent Computer System) อย่างได้ผล นอกจากนี้ ANN ยังเป็นเครื่องมือที่มีประสิทธิภาพในการประยุกต์ใช้ในงานต่างๆ ที่เกี่ยวข้องกับการคำนวณและการจดจำ เช่น การจำแนกข้อมูล (Data Classification) การทำนายเหตุการณ์ (Forecasting) การบีบอัดข้อมูล (Data Compression) การกรองสัญญาณ Noise (Noise Filtering) เป็นต้น ในทางคณิตศาสตร์ ANN อาจมองในแง่ของการเป็น Universal Approximator เนื่องจากความสามารถในการกำหนดความสัมพันธ์ระหว่างรูปแบบของข้อมูล Input – Output ซึ่งทำให้สามารถแก้ปัญหาที่ยากและสลับซับซ้อนได้

สำหรับงานทางด้านอุทกวิทยา หรือวิศวกรรมแหล่งน้ำ Dooge (1974) ได้จำแนกแบบจำลองทางอุทกวิทยาไว้ 3 แบบ กล่าวคือ แบบที่ 1 เป็นแบบจำลองประเภท Physically Based Distributed Model แบบที่ 2 เป็นแบบ Lumped Conceptual Model และแบบที่ 3 เป็นแบบ Black Box Model โดยโครงข่ายประสาทเทียมถูกจัดให้อยู่ในประเภทที่ 3

นับตั้งแต่ศตวรรษที่ 19 เป็นต้นมา ANN ได้เริ่มเข้ามามีบทบาทมากขึ้น เช่น ใช้ในการทำนายอัตราการไหลในแม่น้ำ หรือ การทำนายระดับน้ำ การจำลองกระบวนการเกิดฝน และน้ำท่า การทำนายความเค็มบริเวณปากแม่น้ำ เป็นต้น ในอดีตการจำลองทางอุทกวิทยาจะพิจารณาบนพื้นฐานของความสัมพันธ์ทางกายภาพของตัวแปรต่างๆ หรือบนพื้นฐานของการวิเคราะห์ทางสถิติ อย่างไรก็ตามแบบจำลองทั้งสองค่อนข้างยุ่งยาก และให้ผลลัพธ์ไม่ค่อยเป็นที่น่าพอใจ ตัวอย่างเช่น ในกรณีที่เกิดฝนตกหนักในลุ่มน้ำ ตัวแปรบางตัวแปรในสมการสมดุลของน้ำ (Water Balance Equation) อาจจะไม่ค่อยมีความสำคัญมากนัก เช่น การระเหย การซึมผ่าน และการกักเก็บน้ำโดยพืช ทั้งนี้เนื่องจากตัวแปรต่างๆ เหล่านี้ไม่ได้มีผลกระทบต่ออัตราการไหล หรือระดับน้ำในช่วงระยะเวลาสั้นๆ

นอกจากนี้ การใช้แบบจำลองแบบดั้งเดิมหรือที่เรียกว่า Conventional Model (แบบจำลองประเภทที่ 1 และ 2) มีความจำเป็นที่จะต้องใช้ข้อมูลทางอุทกวิทยาที่หลากหลายและละเอียด ตัวอย่างเช่น พื้นที่ภูมิประเทศของลุ่มน้ำ โครงข่ายแม่น้ำ คุณลักษณะดิน ปริมาณฝน และอัตราการไหล ซึ่งข้อมูลเหล่านี้อาจไม่สามารถหาได้ครบถ้วน จึงทำให้เป็นการยาก หรือเป็นอุปสรรคต่อการใช้แบบจำลอง โดยเฉพาะในขั้นตอนของการปรับเทียบแบบจำลองให้ทำนายผลได้ใกล้เคียงความเป็นจริงมากที่สุด การใช้แบบจำลองลักษณะนี้สำหรับการคำนวณในระยะยาว ยังเสียเวลาและค่าใช้จ่ายสูง

ปัจจุบันการใช้แบบจำลองโครงข่ายประสาทเป็นที่ยอมรับในความสามารถและความมีประสิทธิภาพ โดยเฉพาะการจำลองพฤติกรรมการณ์การไหลที่มีความสลับซับซ้อนไม่เชิงเส้นและแปรเปลี่ยนไปกับเวลา นอกจากนี้ยังใช้ได้กับพฤติกรรมการณ์การไหลที่ผู้ใช้ไม่มีความจำเป็นที่จะต้องทำความเข้าใจเกี่ยวกับความสัมพันธ์ทางกายภาพของตัวแปรต่างๆ ที่เกี่ยวข้อง เช่น ในกรณีของน้ำท่วมฉับพลัน เป็นต้น อย่างไรก็ตามทั้งนี้ไม่ได้หมายความว่า แบบจำลองโครงข่ายประสาทไม่คำนึงถึงพื้นฐานความรู้ หรือ ข้อมูลจากประสบการณ์ทำงาน ในทางตรงกันข้ามจะลดความยุ่งยากในการใช้แบบจำลอง และยังสามารถระบุรูปแบบของความสัมพันธ์ที่กำลังค้นหาได้อย่างถูกต้อง


2.1 หลักการทำงานของโครงข่ายประสาท

ANN เป็นแนวคิดที่แตกต่างกับแนวคิดทางด้าน Conventional อย่างสิ้นเชิงในการจำลองพฤติกรรมการณ์การไหลโดยการใช้แบบจำลองโครงข่ายประสาทเทียม เราไม่มีความจำเป็นที่จะต้องกำหนดหรือสร้างสมการควบคุมการไหล เพียงแต่เรารวบรวมข้อมูลอินพุต (Input) และเอาต์พุต (Output) ไว้เป็นคู่ๆ การใช้แบบจำลองคณิตศาสตร์ หรือ แบบจำลองทางสถิติจะต้องสร้างความสัมพันธ์ระหว่างอินพุต (Input) และเอาต์พุต (Output) ซึ่งอยู่ในรูปของสมการ Explicit แต่โครงข่ายประสาทเทียมจะทำการสร้างความสัมพันธ์ระหว่างอินพุต (Input) และเอาต์พุต (Output) โดยกระบวนการของการเรียนรู้จากข้อมูลที่มีอยู่ ความสัมพันธ์ดังกล่าวไม่มีการกำหนดในรูปของสมการ Explicit

2.2 วิวัฒนาการของ ANN

การศึกษาเกี่ยวกับโครงข่ายประสาทเทียมเริ่มจากงานวิจัยของ McCulloch and Pitts (1943) ต่อมาในปี ค.ศ. 1949 Hebb เป็นคนแรกที่แนะนำโครงข่ายที่มีการประมวลผลจากการเรียนรู้เหมือนเซลล์สมองซึ่งเรียกว่า Hebbian Learning และต่อมาได้นำมาใช้ในการออกแบบโครงข่ายประสาทเทียมต่างๆ มากมาย การใช้เครื่องคอมพิวเตอร์ในการคำนวณโดยโครงข่ายประสาทเทียมได้เริ่มขึ้นอย่างเป็นทางการ เมื่อปี ค.ศ. 1956 โดย Rochester และเพื่อน ซึ่งเป็นการเริ่มยุคของ Artificial Intelligent (AI) อย่างแท้จริง นับจากนั้นได้นักวิจัยหลายท่านพัฒนาโครงข่ายประสาทเทียมขึ้นมาหลายแบบ เช่น ในปี ค.ศ. 1958 Rosenblatt ได้พัฒนาโครงข่ายเพอร์เซพตรอน (Perceptron) ซึ่งมีพื้นฐานการทำงานเป็นแบบ 3 ชั้น กล่าวคือ ชั้นอินพุต (Input Layer) ชั้นแอสโซซิเอชัน (Association Layer) และชั้นเอาต์พุต (Output Layer) ในปี ค.ศ. 1960 Widrow ได้พัฒนาโครงข่าย ADALINE (ADaptive LInear NEuron) ซึ่งต่อมามีการปรับปรุงเป็นโครงข่ายที่มีชื่อภายหลังว่า MADALINE (Multiple ADALINEs) หลังจากนั้นนักวิจัยหลายท่านให้ความสนใจเกี่ยวกับ Associative Memory จนกระทั่งในปี ค.ศ. 1982 จึงเกิดโครงข่าย Hopfield ซึ่งเป็นโครงข่ายประเภท Recurrent และสามารถนำมาประยุกต์แก้ปัญหา Travelling Salesman ทำให้ Hopfield ได้รับรางวัลโนเบลทางสาขาฟิสิกส์ในปีนั้น วิวัฒนาการของ ANN แต่ละยุคได้แสดงไว้ใน รูปที่ 2.2-1

ส่วนที่สำคัญที่สุดในการพัฒนาโครงข่ายประสาทเทียมในระยะหลังของงานวิจัย มักจะเป็นการค้นหาคะบวนการเรียนรู้เพื่อใช้ในการแก้ไขน้ำหนัก (Weights) ในโครงข่าย จึงเกิดเป็นทฤษฎี Back-propagation ซึ่งเป็นทฤษฎีที่จะทำการปรับค่าถ่วงน้ำหนักจากชั้นเอาต์พุต (Output) ไปยังชั้นอินพุต (Input) การนำเสนอทฤษฎีดังกล่าวทำให้งานวิจัยทางโครงข่ายประสาทเทียมได้รับความนิยมมากขึ้น ตั้งแต่ปี ค.ศ. 1980 เมื่อเกิดกระบวนการคิดค้น Multilayer Perceptron (Rumelhart, 1986) ซึ่งสามารถจัดอุปสรรคของ Single Layer Perceptron



รูปที่ 2.2-1 วิวัฒนาการของ ANN

นอกจากนี้ยังได้มีการนำเสนอ Parallel Distribution Processing ซึ่งประกอบไปด้วย 8 เรื่องหลักๆ ดังนี้

- 1) การจัดตั้งหน่วยกระบวนการ (Processing Unit)
- 2) สภาพการกระตุ้น (State of Activation)
- 3) Output Function สำหรับแต่ละหน่วย
- 4) ระบบการเชื่อมโยงระหว่างหน่วย (Connectivity Among Units)
- 5) กิจกรรมการเคลื่อนตัวผ่านโครงข่ายที่เชื่อมโยงกัน
- 6) กฎการกระตุ้น (Activation Rule)
- 7) กฎการเรียนรู้ (Learning Rule)
- 8) สิ่งแวดล้อมภายในระบบ

Rumelhart (1986) ได้เสนอโครงข่าย Back-Propagation ซึ่งพัฒนามาจากโครงข่าย Single Layer Perceptron โดยแบ่งการทำงานออกเป็นสองขั้นตอน ในขั้นตอนแรก ข้อมูลในหน่วยของชั้นอินพุต (Input) จะเคลื่อนตัวผ่านไปยังโครงข่ายและประมวลผลออกมาในหน่วยของชั้นเอาต์พุต (Output) หลังจากนั้น เอาต์พุตจะถูกนำมาเปรียบเทียบกับเป้าหมาย นำมาซึ่งความผิดพลาดที่เกิดขึ้นในขั้นตอนที่สองเป็นขั้นตอนของการเคลื่อนตัวกลับ (Backward Pass) เพื่อทำการปรับแก้ค่าถ่วงน้ำหนัก (Weights) ของข้อมูลอินพุตและของ Bias


ตั้งแต่นั้นเป็นต้นมาจึงได้มีการพัฒนาโครงข่ายต่างๆ ขึ้นมามากกว่า 50 โครงข่าย อย่างไรก็ตามการนำมาใช้แก้ปัญหาทางวิศวกรรมโยธาโดยเฉพาะในสาขาวิศวกรรมแหล่งน้ำมีน้อยมาก เริ่มจาก French et. al. (1992) ได้พัฒนาโครงข่ายเพื่อทำนายปริมาณฝนที่ตกตามสถานที่และเวลาต่างๆ Crespo and Mora (1993) ประยุกต์ใช้หลักการของแบบจำลองโครงข่ายประสาทเทียมกับการประมาณการเกิดภัยแล้ง และมีการพัฒนาแบบจำลองโครงข่ายประสาทเทียมเพื่อจำลองการเกิดฝนและน้ำท่า โดยพบว่า ANN เป็นวิธีการที่มีประสิทธิภาพมากที่สุด เมื่อเปรียบเทียบกับแบบจำลองทางคณิตศาสตร์อื่นๆ และเมื่อเร็วๆ นี้ Campoio et. al. (1999) พัฒนาโครงข่ายประสาทเทียม ในการวิเคราะห์ และทำนายระดับน้ำท่วมของแม่น้ำ Taghamento ในประเทศอิตาลี ในช่วงเวลาที่มีฝนตกหนัก ผลการคำนวณ พบว่ามีความถูกต้องแม่นยำมาก Liong et. al. (2001) ได้ประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียม เพื่อช่วยในการวางแผนป้องกันน้ำท่วมในประเทศบังคลาเทศ จากผลการศึกษาทำให้ ANN เป็นเครื่องมือที่สามารถใช้ในการเตือนภัยน้ำท่วมอย่างได้ผล

สำหรับงานวิจัยภายในประเทศไทย เริ่มจาก เสรี (2542) ได้พัฒนาโครงข่ายประสาทเทียมในการพยากรณ์น้ำท่าแม่น้ำมูลจังหวัดอุบลราชธานี ผลการคำนวณยังมีความคลาดเคลื่อนเนื่องมาจากข้อจำกัดของข้อมูล ต่อมา เสรี (2543) ได้ประยุกต์ใช้โครงข่าย Back-Propagation ในการพยากรณ์ระดับน้ำลุ่มแม่น้ำยม บริเวณจังหวัดแพร่ (สถานี Y.1C) และจังหวัดสุโขทัย (สถานี Y.4) โดยพบว่า ให้ผลการคำนวณที่ดีมากและมีประสิทธิภาพมากกว่า 95% นอกจากนี้ เสรี (2544) ยังใช้โครงข่ายประเภทเดียวกัน

ทำการพยากรณ์ระดับน้ำทะเลหนุน บริเวณปากแม่น้ำเจ้าพระยา (สถานีป้อมพระจุลจอมเกล้าฯ) รัชชัช และคณะ (2550) ได้ประยุกต์ใช้โครงข่ายประสาทเทียมเพื่อให้เป็นแบบจำลองในการทำนายปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อนป่าสักชลสิทธิ์กรณีจากระบบโทรมาตรหรือแบบจำลอง MIKE 11 - GIS สัมเหลว ผลการวิจัยพบว่าแบบจำลองสามารถใช้ในการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อนป่าสักชลสิทธิ์ล่วงหน้า 1 วันและ 2 วันได้ใกล้เคียงกับความจริง

2.3 แนวคิดเบื้องต้นโครงข่ายประสาทเทียม


สำหรับหลักการทำงานเบื้องต้นของโครงข่ายประสาทเทียม ได้แสดงไว้ดังรูปที่ 2-3-1 ซึ่งสามารถอธิบายได้ว่า ในการทำงานของโครงข่ายอาจจะมี Input หลายตัวที่เป็นตัวกระตุ้นให้เกิด Output โดยที่แต่ละ Input จะมีอิทธิพลต่อ Output ต่างกัน ซึ่งวัดได้จากค่าถ่วงน้ำหนัก (Weight) นั้นเอง



รูปที่ 2-3-1 หลักการทำงานเบื้องต้นของ ANNs

จากรูป $X (X_1, X_2, X_3)$ จะเป็น Input ที่มีความสัมพันธ์กับ Y ที่เป็น Output แบบไม่เชิงเส้น ดังนั้นจะได้ฟังก์ชัน $f(\text{net})$ ที่เป็นแบบไม่เชิงเส้น (Nonlinear function) ดังสมการที่ (ดูรูปที่ 2.3-2)

$$\text{net} = X_1 W_1 + X_2 W_2 + X_3 W_3 = \sum XW$$



รูปที่ 2.3-2 ฟังก์ชันการกระตุ้น

ในกระบวนการทำงานของโครงข่ายประสาทเทียม จะมีกระบวนการเรียนรู้หลายรูปแบบ การเรียนรู้มีวัตถุประสงค์ในการปรับแก้ค่าถ่วงน้ำหนัก (Weight) ให้เหมาะสม นำมาซึ่งค่า Output ที่ใกล้เคียงกับเป้าหมายมากขึ้น ดังนั้นจากหลักการทำงานดังกล่าวข้างต้น เราจึงสามารถนำโครงข่ายประสาทเทียมมาประยุกต์เพื่อใช้ในการแก้ปัญหาต่างๆ ได้อย่างกว้างขวาง

2.4 ประเภทของ ANN ในเชิงการใช้งาน

1) แบบจำลองโครงข่ายประสาทเทียมเพื่อการระบุกลุ่ม

โครงสร้างของ ANN ประเภทนี้ที่ได้รับความนิยมสูงสุด คือ โครงข่าย Multilayer Perceptron โดยการเรียนรู้แบบ Back-Propagation (BP) ซึ่งมีการทำงานคล้ายๆ กับโครงข่ายประสาทรับความรู้สึกที่มีโครงสร้างการทำงานมากกว่า 1 ชั้น แบบจำลองดังกล่าวประกอบไปด้วยโครงสร้างทั้งหมด 3 ชั้น คือ ชั้นอินพุต (Input Layer) ชั้นแอบแฝง (Hidden Layer) และชั้นเอาต์พุต (Output Layer) สำหรับกระบวนการเรียนรู้จะใช้วิธีการเรียนรู้จากรูปแบบของข้อมูล Input และ Output ที่มีอยู่ โดยที่ข้อมูล Input จะถูกป้อนเข้าไปในแต่ละหน่วยในชั้นแรก จากนั้นแต่ละข้อมูล Input จะถูกคูณด้วยค่าถ่วงน้ำหนัก (Weight) เฉพาะของการเชื่อมโยงระหว่างชั้นซึ่งค่าเริ่มต้นของค่าถ่วงน้ำหนัก (Weight) อาจถูกกำหนดโดยการสุ่ม (Random) ผลคูณที่ได้จะนำมารวมกันเพื่อแปลงเป็น Output โดยผ่านฟังก์ชันการกระตุ้น (Activation Function) จากนั้น Output ที่ได้จะถูกนำไปเปรียบเทียบกับข้อมูลจริงหรือเป้าหมายเพื่อนำไปสู่การปรับแก้ค่าถ่วงน้ำหนัก และเพื่อลดค่าความแตกต่างหรือข้อผิดพลาดในแต่ละรอบของการคำนวณ การปรับค่าถ่วงน้ำหนัก จะดำเนินการไปจนกระทั่งข้อผิดพลาดมีค่าน้อยและยอมรับได้ การคำนวณจึงจะสิ้นสุด

2) แบบจำลองโครงข่ายประสาทเทียมสำหรับการจัดรูปแบบข้อมูล

การเรียนรู้ความเกี่ยวข้องกันเป็นอีกมุมหนึ่งของการพัฒนาความสามารถของโครงข่ายประสาทเทียม โดยการพยายามที่จะให้โครงข่ายจดจำ “ความสัมพันธ์ หรือ ความเกี่ยวข้อง” ของข้อมูลแต่ละรูปแบบไว้ เมื่อมีการแสดงรูปแบบหนึ่งต่อโครงข่าย โครงข่ายก็จะให้ผลลัพธ์เป็นรูปแบบที่เคยเรียนรู้และจดจำไว้ว่าเป็นรูปแบบข้อมูลที่เกี่ยวข้องกับรูปแบบที่ป้อนเข้าไป

ลักษณะของความเกี่ยวข้องกันถูกจัดไว้เป็น 2 ลักษณะ คือ ถ้ารูปแบบของข้อมูลเกี่ยวข้องกันเป็นรูปแบบเดียวกันจะเรียกว่า เป็นความเกี่ยวข้องแบบออโตแอสโซซิเอชัน (Autoassociation) ซึ่งเหมาะสำหรับการประยุกต์ใช้ในการทำรูปแบบให้สมบูรณ์ ในกรณีที่รูปแบบที่เกี่ยวข้องกันไม่ใช่รูปแบบเดียวกัน จะเรียกว่า แบบเฮเทอโรแอสโซซิเอชัน (Heteroassociation)

3) แบบจำลองโครงข่ายประสาทเทียมสำหรับการหาค่าที่เหมาะสม

การหาค่าที่เหมาะสมเป็นอีกตัวอย่างหนึ่งที่นิยมประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียม เช่น กรณีของการปัญหา Traveling Salesman ซึ่งต้องการเส้นทาง หรือระยะทางที่สั้นที่สุดของการเดินทางของ Salesman ไปตามเมืองต่างๆ แล้วกลับมาสิ้นสุดที่เมืองเริ่มต้น โครงข่ายประเภทนี้มักจะ

อาศัยเทคนิคจากทฤษฎีความน่าจะเป็นหรือสถิติเข้ามาแก้ปัญหาตัวอย่างเช่น โครงข่าย Boltzman Machine

4) แบบจำลองโครงข่ายประสาทเทียมประเภทจัดตัวเอง

การจัดตัวเอง หมายถึง ความสามารถในการเรียนรู้ และจัดข้อมูลโดยไม่ต้องมีเป้าหมายเป็นตัวชี้นำ กล่าวคือ เป็นการเรียนรู้โดยไม่มีครูสอน (Unsupervised Learning) แบบจำลองประเภทนี้เหมาะสำหรับการประมวลลักษณะเชิงเรขาคณิตของรูปทรงต่างๆ ซึ่งยากแก่การกำหนดค่าจำกัดความในทางคณิตศาสตร์ หรือการพยายามจัดกลุ่มรูปแบบโดยไม่มีแนวทางมาให้ เช่น การจัดแบ่งคนออกมาเป็นผู้ชาย ผู้หญิง หรือจัดเป็นคนแก่ คนหนุ่ม และเด็ก เป็นต้น สิ่งเหล่านี้เป็นความสามารถที่มีโดยธรรมชาติของสิ่งมีชีวิต แนวคิดของการจัดตัวเองโดยส่วนใหญ่จะใช้หลักการเรียนรู้เชิงแข่งขัน (Competitive Learning) โดยกลไกที่เรียกว่า “ผู้ชนะได้ไปทั้งหมด” (Winner Take All) ตัวอย่างของแบบจำลองประเภทนี้ เช่น โครงข่ายโคโฮเนน (Kohonen Network)

2.5 การประยุกต์ใช้โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมสามารถนำมาประยุกต์ใช้ในแอปพลิเคชันต่างๆ ซึ่งจะกล่าวโดยกว้างๆ ดังนี้

1) **Constraint Satisfaction** เป็นลักษณะของการแก้ปัญหาที่มีตัวแปรหลายตัวเป็นตัวควบคุมให้เกิดเอาต์พุตที่มีค่าแน่นอน ตัวอย่างเช่น ปัญหาของ Traveling Salesman ซึ่งเป็นลักษณะของปัญหาที่มีเงื่อนไขควบคุมอยู่ และต้องคำนึงถึงความเหมาะสมด้วย เงื่อนไขดังกล่าวคือ การที่จะต้องเดินทางไปทุกเมืองที่กำหนดในปัญหา และยังคงคำนึงถึงความเหมาะสมในการเลือกเส้นทางที่สั้นที่สุดที่สามารถเดินทาง ได้จริง จึงจะแก้ปัญหานี้ได้อย่างมีประสิทธิภาพ

2) **Content Addressable Memories** เป็นการนำเอาความสามารถของ ANN ที่สามารถเรียนรู้ และจดจำรูปแบบในลักษณะของความสัมพันธ์ระหว่าง อินพุต และเอาต์พุต

3) **Controls** การนำ ANN ไปใช้ในการเรียนรู้ และควบคุมการขับเคลื่อนหุ่นยนต์ รวมไปถึงหน้าที่ที่ต้องช่วยในการขับเคลื่อน ผลิตภัณท์หลายอย่างที่เกิดขึ้นในประเทศญี่ปุ่นได้นำ ANN มาช่วยในการบริหารและจัดการด้านขบวนการผลิต

4) **Data Compression** โครงข่ายประสาทนี้ใช้การเรียนรู้และการคำนวณเพื่อลดจำนวนอินพุตที่ใช้ในแอปพลิเคชันที่มีข้อมูลจำนวนมาก ๆ ถูกเก็บเอาไว้ และถูกประมวลผล ตัวอย่างเช่น กรณีของการทำงานของภาพถ่ายดาวเทียม

5) **Diagnostics** การใช้ ANN ในงานวิจัยต่างๆ เช่น ทางวิศวกรรม ทางด้านการแพทย์ ก็นำเอา ANN มาใช้ในการวินิจฉัยโรคที่ซับซ้อน โดย ANN จะต้องเก็บความสัมพันธ์ระหว่างอินพุต ที่เป็นลักษณะการ หรือ พฤติกรรมที่ผิดปกติ กับเอาต์พุตที่เป็นการระบุโรคของผู้ป่วย

6) Forecasting การนำ ANN มาใช้ในการพยากรณ์เหตุการณ์ต่างๆ หรือแม้แต่ผลิตภัณฑ์ หุ้น เป็นต้น สามารถใช้ได้อย่างมีประสิทธิภาพ เช่น การพยากรณ์แนวโน้มของการขายผลิตภัณฑ์ตัวใหม่ที่เพิ่งออกมาสู่ตลาด ทำให้บริษัทผู้ผลิตสามารถวางแผนการทางตลาดได้อย่างมีประสิทธิภาพมากขึ้น การพยากรณ์สภาพอากาศ เป็นแอปพลิเคชันหนึ่งที่นิยมใช้กันในปัจจุบัน ในส่วนของการจัดการเรื่องธุรกิจการบิน สามารถประยุกต์ใช้ ANN หาแนวโน้มการเดินทางของลูกค้า เพื่อใช้ในการวางแผนสนองตอบกับความต้องการในอนาคต ทางด้านธุรกิจการเงิน ANN ใช้ในการพยากรณ์อัตราแลกเปลี่ยนและการจัดการหลักทรัพย์เพื่อการลงทุน นอกจากนี้ทางด้านการทหารยังได้นำ ANN ไปใช้ในการวิเคราะห์จุดยุทธศาสตร์ที่ตั้งของข้าศึก

7) General Mapping การนำ ANN ไปประยุกต์ใช้ในแอปพลิเคชันต่าง ๆ มักอยู่ภายใต้พื้นฐานการนำความสามารถในการเรียนรู้ที่จะใช้ในการตัดสินใจจากการสอนให้โดยตัวอย่างในอดีต เช่น บริษัท Yamaha นำไปใช้ในการวิเคราะห์ตัวโน้ตจากเสียงกีตาร์ เป็นต้น

8) Mutisensor Data Fusions เป็นการนำ ANN ไปประยุกต์ใช้ในกระบวนการการประมวลผลข้อมูลต่างๆ จากแหล่งข้อมูลหลายแบบ ตัวอย่างเช่น การนำไปใช้ในการจัดทำระบบความปลอดภัย ข้อมูลที่สามารถพิจารณาได้จากหน้าตาของผู้ใช้ (Image Processing)

9) Pmization เป็นการแก้ปัญหาเพื่อหาความเหมาะสมของแนวทาง เพื่อให้ได้ผลลัพธ์ของปัญหาอย่างมีประสิทธิภาพที่สุด

10) Pattern Recognition เป็นการใช้ ANN เพื่อการเรียนรู้และรับรู้ลักษณะของปัญหาที่สลับซับซ้อน เช่น การมองเห็นวัตถุต่างๆ การวิเคราะห์เสียงพูดเพื่อแปลเป็นข้อความ เป็นต้น

ตัวอย่างการประยุกต์ใช้แบบจำลอง ANNs ในการพยากรณ์ด้านวิศวกรรมทรัพยากรน้ำ แสดงในตารางที่ 2.5-1

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
Tawatchai Tingsanchali	Forecasting model of Chao Phraya river flood levels at Bangkok.	Proceedings, International Conference on 'The Chao Phraya Delta: Historical Development, Dynamics and Challenges of Thailand's Rice Bowl	2543	- To develop a neural network model for forecasting hourly flood water levels of the Chao Phraya River at Bangkok Memorial Bridge.	- A neural network model with back propagation	- The model developed was found to perform very well in both calibration and verification. - The neural network model is however still dominated by trial and error process in many aspects. It is important to mention that the selection of the network architecture significantly influences the output performance of the model and the computational time. - The model requires water level or discharge data but not the topographical data - A study is being conducted to use the neural network model to forecast hourly water levels and discharges for more time steps ahead in the Chao Phraya river.

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
Tawatchai Tingsanchali (ต่อ)						- More studies are encouraged to apply neural network models for flood forecasting in other tidal rivers of different characteristics so that models can be applied with confidence in operational flood forecasting and warning.
Tawatchai Tingsanchali and Mahesh Raj Gautam	Application of Tank, NAM, ARMA and neural network models to flood forecasting.	งานวิจัย AIE	2543	- Comparison of the Tank and NAM models in rainfall-runoff (R-R) transformation - Application of the R-R models along with stochastic models - Evaluation of the performances of neural network models in R-R transformation and in flood forecasting with reference to the combined deterministic (tank or NAM) and stochastic model	- Tank model - NAM model - ARMA model - Neural network model	- The Tank and NAM models were calibrated and verified and found to give similar results that found to improve significantly by coupling stochastic and deterministic models (Tank and NAM) for updating forecast output. - The neural network model (NN model) does not require knowledge of catchment characteristics and internal hydrological processes

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ข้อร้อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
Tawatchai Tingsanchali and Maresh Raj Gautam (ต่อ)						- The NN model give good forecasts based on available rainfall, evaporation and runoff data
Thet Yee Win	Daily flood forecasting: A neural network model of Prasae river.	วิทยานิพนธ์ AIT	2543	- To develop a suitable daily flood forecasting model with updating facilities using the Back Propagation Neural Network Model (BPNN) for forecasting daily discharge at various stations of the Prasae River Basin - To develop the BPNN model and Auto-regressive (AR) model, which is a combination of the BPNN and AR model - To forecast the daily inflow to the proposed Prasae Reservoir - To forecast the daily outflow from the Prasae River Basin to the Gulf of Thailand	- The Neural Network Model	- The NN model based on back propagation algorithm was applied for daily flood forecasting at five station - The combination of NN and AR models could highly increase the NN model efficiency if NN model is based on forward pass only without the back propagation algorithm

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
Tawatjai Tingsanchali (ต่อ)		Helsingor, Denmark				coupled with the stochastic model of forecast error time series. - The performance of the Tank model is very much dependent on the input data. The output of the Tank model controls the accuracy of forecast in terms of timeliness and magnitude, which are both very important. - The performance of stochastic models, such as the AR model, in improving the forecast accuracy of the Tank model was found highly dependent on the persistence of error time series.
Tawatjai Tingsanchali	Back Propagation Neural Network for Flood Forecasting.	Seminar on Artificial Intelligence	2544	- เพื่อใช้ศึกษาวิธีที่สนใจในการใช้ Neural Network เพื่อการศึกษาด้าน Rainfall-Runoff Modeling และการ	- Neural Network with Back Propagation	- การปรับปรุงการพยากรณ์อัตราการไหล ของน้ำ การข้ามในแม่น้ำปลึก อ.เขตรบร้อน และแม่น้ำประแสร์

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
Tavatchai Tingsanchali (ต่อ)		in Water Resources Engineering.		ไหลของน้ำในแม่น้ำ		จะอยู่ที่แปรเปลี่ยนไปตามเวลา
Tavatchai Tingsanchali, Manusthapirom, C.	A neural network model for flood forecasting in tidal rivers.	International Association for Hydraulic Research Beijing	2544	- To develop a neural network model for forecasting hourly discharges and water levels of the Chao Phraya River for three in advance at Bangkok Memorial Bridge. ไทย	- Back propagation neural network model (BPNN model).	- The BPNN model developed for 1 hour, 2 hour and 3 hour ahead forecasts was found to perform very well in both training and testing. - The efficiency index of flood forecasting for both water levels and discharges ranges from 87-99% for model training to 80-96% in model testing. It is important that the selection of the neural network architecture significantly influences the output performance of the model and the computational time. - The model has the advantage that it requires only water level and

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพัฒนาและเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
รัชมี สุวรรณวีระกัทร (ศูนย์คอมพิวเตอร์ ๑ น. ขอนแก่น) ธนวัฒน์ จารุพงษ์สกุล (ภาควิชาธรณีวิทยา ๑) สัญญา สราภิรมย์ (กองธรณีวิทยา กรม ทรัพยากรธรณี)	การประยุกต์ใช้ข้อมูลระยะไกล กับการศึกษาสภาพน้ำท่วมใน บริเวณที่ราบภาคกลางตอนล่าง	งานวิจัยเอก เอกสาร ประกอบ การประชุม วิชาการ เทคโนโลยี อวกาศกับ อุทกวิทยา	2544	- เพื่อให้สามารถวิเคราะห์ภาพรวม และแนวโน้มของสถานะน้ำท่วมได้ อย่างชัดเจน	- คิวเทียมแลนด์เซา ระบบ ในแบบจำลอง 1 ภาพ ครอบคลุมพื้นที่ 185 x 185 พ.ม.	- ภาพดาวเทียมสามารถใช้เป็น เครื่องมือในการติดตามสถานะน้ำ ท่วมได้อย่างมีประสิทธิภาพทั้งนี้ เนื่องจากคุณสมบัติของดาวเทียมที่ สามารถบันทึกข้อมูลซ้ำ ณ บริเวณ เดิม ต่อมาเวลาที่กำหนดแบบคงที่ ทำให้สามารถเลือกดูรูปแบบที่เกาะ สมและสอดคล้องกับสถานะน้ำท่วม ถึงแม้จะมีอุปสรรคเกี่ยวกับการปิดบัง ข้อมูลเนื่องจากจากเมฆ
วุฒิชัย บุญส่อง	การประยุกต์ใช้ระบบโครงข่าย ประสาทเทียม ในการคาดการณ์ ปริมาณน้ำท่ารายวัน	วิทยานิพนธ์ มหาวิทยาลัย เทคโนโลยี มหานคร	2544	- เพื่อประยุกต์ใช้ระบบโครงข่าย ประสาทเทียมแบบ Back Propagation ชนิด Fully Link Multi- layer Feed Forward ในการ คาดการณ์น้ำท่ารายวันล่วงหน้า	- Neural Network	- ผลการคาดการณ์ปริมาณน้ำท่ารายวัน โดยใช้ระบบโครงข่ายประสาทเทียม มีค่าสัมประสิทธิ์ความแม่นยำ (R ²) อยู่ในเกณฑ์ดี สำหรับการคาดการณ์ ปริมาณน้ำท่ารายวัน 1 วันล่วงหน้า และค่าสัมประสิทธิ์ความแม่นยำ (R ²) มีค่าลดลง สำหรับรับการคาดการณ์ ปริมาณน้ำท่ารายวัน 2 วันล่วงหน้า

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
เสรี สุภราทิตย์	การประยุกต์ใช้ Neuro-genetic algorithm ในการพยากรณ์และเตือนภัยน้ำท่วม	งานวิจัย รังสิต	2544	- เพื่อพัฒนาโปรแกรมและการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมร่วมกับ Genetic algorithm ในการพยากรณ์และเตือนภัย น้ำท่วม	- Neuro-genetic algorithm - โครงข่ายแบบเบี่ยงเวลา (Time delay neural network, TDNN)	- สามารถใช้ผลการคำนวณเป็นที่น่าสนใจ สามารถนำมาสร้างระบบเตือนภัยได้อย่างเหมาะสม - ระบบการจัดการและการประสานงานมีความจำเป็นห้องจัดตั้ง Flood Operation Room
เสรี สุภราทิตย์, ชัยยุทธ ชินณะราศรี และ ทรงพล โนนสว่าง	การพยากรณ์ระดับน้ำที่ขนาดใหญ่โดยใช้โครงข่ายประสาทเทียม	งานวิจัย การประชุม วิชาการ วิศวกรรม แหล่งน้ำแห่ง ชาติ ครั้งที่ 1	2544	- เพื่อพยากรณ์ระดับน้ำและเตือนภัย น้ำท่วมในเขตอำเภอหาดใหญ่ จังหวัดสงขลา โดยใช้โครงข่ายประสาทเทียมแบบ Back propagation	- โครงข่ายประสาทเทียมแบบ Back propagation	- โปรแกรมพยากรณ์ระดับน้ำที่เกิดขึ้นล่วงหน้าเป็นเวลา 1-3 วัน ให้ผลการคำนวณเป็นที่น่าสนใจอย่างมาก ให้ความสำคัญแก่การลดผลกระทบทางสถิติมากที่สุด
อนุจิต รัตนสุวรรณ	การประยุกต์ระบบสารสนเทศภูมิศาสตร์ และการสำรวจระยะไกลในการศึกษาผลกระทบจากการเปลี่ยนแปลงการใช้ประโยชน์ที่ดิน คำนวณน้ำท่าบริเวณลุ่มน้ำแม่แจ่ม จังหวัดเชียงใหม่	วิทยานิพนธ์ เกษตรฯ	2544	- เพื่อศึกษาน้ำท่วม ความสัมพันธ์ของการเปลี่ยนแปลงการใช้ประโยชน์ที่ดิน ที่มีผลต่อปริมาณน้ำท่าในลุ่มน้ำแม่แจ่ม	- GIS - Remote sensing	- การประเมินค่าน้ำไปลำธาร โดยใช้ที่จัดเก็บข้อมูลการเปลี่ยนแปลงการใช้ประโยชน์ที่ดิน เพื่อศึกษาถึงปริมาณน้ำท่าที่ประกอบกับปริมาณฝน ที่ใช้ในการศึกษาพบว่า สามารถนำใช้ในการศึกษาพบว่า สามารถนำ

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)

ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่ พิมพ์	วัตถุประสงค์	เทคโนโลยี	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
ชูเกียรติ บริสุทธิ์	ระบบเลอมาบอและเจอบนอุปกรณ์	งานวิจัย ทางธรณีวิทยา	2545	- เพื่อศึกษาความสัมพันธ์กับพื้นที่ลุ่มน้ำ ต่าง ๆ โดยประยุกต์ใช้พื้นที่ลุ่มน้ำ ให้เหมาะสม กับน้ำท่วมระยะสั้น พื้นที่เกิด ดินถล่มทางพหุภาคพื้นที่ที่ชุมชนที่อยู่ เชิงเขา	- ระบบโทรมาตร (การวัด สารข้อมูลระยะไกลแบบ อัตโนมัติ) - ข้อมูลดาวเทียม	- เพื่อให้สามารถคาดการณ์ภัยน้ำท่วมได้ ล่วงหน้านานขึ้น ควรนำระบบ คาดการณ์ดังกล่าวมาประยุกต์ใช้ ได้แก่ ดาวเทียมเรดาร์ แบบจำลอง สภาพอากาศเชิงตัวเลข(NWP) มาใช้ จะเป็นประโยชน์มากขึ้น
เกตุเกียรติ สุวิไลกุล ทรงศักดิ์ แอ้มพวงมา จุฑารัตน์ รัตนบุษย์ นลินี จันทกมล และ เสรี สุกรทิพย์	การพัฒนา Software ระบบผู้เชี่ยวชาญ สำหรับการเก็บข้อมูลภัยน้ำท่วม	งานวิจัย รังสิต	2545	- เพื่อประยุกต์ใช้โครงข่ายประสาท เทียมแบบ Back Propagation ในการ พยากรณ์น้ำท่วมด้วยข้อมูล บริเวณ จ.สุโขทัย - เพื่อพัฒนา Software ระบบผู้เชี่ยวชาญ สำหรับการเก็บข้อมูลภัยน้ำท่วม	- Expert System For Flood Forecasting - โครงข่ายประสาทเทียม แบบ Back Propagation	- ใช้ทฤษฎีของ โครงข่ายประสาท เทียมแบบ Back Propagation ร่วมกับ การพัฒนาโปรแกรมในลักษณะของ Expert System ในการพยากรณ์ระดับ น้ำ - จำกัดข้อมูลอินพุตที่จำนวน 6 ข้อ มูล และเอาต์พุตที่ 1 ข้อมูล - ผลการศึกษา พบว่า แบบจำลองที่ พัฒนานี้ สามารถใช้ได้จริง ประสิทธิภาพ และเหมาะสมในการใช้ เตือนภัยล่วงหน้า เพื่อลดผลกระทบ จากความเสียหายที่อาจจะเกิดขึ้น

ตารางที่ 2.5-1 รายละเอียดเกี่ยวกับงานวิจัยด้านการพยากรณ์และเตือนภัยน้ำท่วม โดยใช้แบบจำลอง ANNs (ต่อ)


ชื่อ	ชื่อเรื่อง	สถาบันการศึกษา	ปีพ.ศ.ที่พิมพ์	วัตถุประสงค์	ทฤษฎี/โมเดล	ผลการศึกษา ปัญหา / ข้อเสนอแนะ
นพคุณ แก้วสิงห์	การประยุกต์ใช้เทคโนโลยีระบบสารสนเทศภูมิศาสตร์ในการศึกษาอิทธิพลของลักษณะทางกายภาพของกลุ่มน้ำต่อลักษณะการไหลของน้ำในลำธารของกลุ่มน้ำภาคเหนือ	วิทยานิพนธ์ มหาวิทยาลัยเทคโนโลยีสุรนารี	2545	- ศึกษาอิทธิพลของลักษณะทางกายภาพของกลุ่มน้ำต่อลักษณะการไหลของน้ำในลำธาร โดยการใช้โปรแกรม GIS	- Correlation matrix - ประยุกต์ใช้ multiple linear regression ที่ใช้วิธี stepwise	- ได้ถามคำถามถึงปัจจัยที่มีผลต่อการเกิดภัยน้ำท่วม - ลักษณะการไหลของน้ำเกิดจากหลายกลุ่ม - โปรแกรมของ Multiple linear regression ที่ใช้วิธี Stepwise - การประยุกต์ใช้ GIS ในการศึกษา ปัจจัยทางภูมิศาสตร์ที่มีผลต่อการเกิดภัยน้ำท่วม - ความเหมาะสมของพื้นที่ในการศึกษา - ความใกล้เคียงกับพื้นที่จริง
นลินี จันทพงศ์ และ เสรี สุกราทิพย์	การพยากรณ์อุทกภัยและระดับน้ำท่วมเพื่อการเตือนภัยน้ำท่วม	งานวิจัย รังสิต	2555	- เพื่อประยุกต์ใช้ข้อมูลมาใช้ในการพยากรณ์ระดับน้ำสำหรับเตือนภัยน้ำท่วม	- อุทกวิทยา - โปรแกรม Neural Network - Genetic Optimizer (Dendro)	- บรรยายความสัมพันธ์ของระดับน้ำที่ เกิดภัยน้ำท่วม - ใช้โปรแกรม Back Propagation - สามารถใช้ผลการคำนวณที่แม่นยำ - เพื่อใช้ในการพยากรณ์ระดับน้ำ - ผลการพยากรณ์ระดับน้ำที่แม่นยำ - สามารถเตือนภัยน้ำท่วมได้ก่อนเกิดภัยน้ำท่วม

บทที่ 3

ถอดรหัส ANNs

เพื่อให้การเรียนรู้แบบจำลอง ANN นั้นง่ายขึ้น จึงควรทำความเข้าใจเกี่ยวกับขั้นตอนการทำงานของแบบจำลองและทดลองฝึกฝน ถอดรหัสและคำนวณเลียนแบบคอมพิวเตอร์ด้วยมือก่อน โดยตัวอย่างการคำนวณแปลมาจากการสอนของท่าน ศ.ดร. ธวัชชัย ดิงสัญชลี สถาบันเทคโนโลยีแห่งเอเชีย

ตัวอย่างที่นำมานี้เป็นตัวอย่างการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำประแสร์ จังหวัดระยอง ซึ่งตั้งอยู่ในลุ่มน้ำปราจีนบุรี (แสดงดังรูป 3-1)



รูปที่ 3-1 พื้นที่ลุ่มน้ำไหลลงอ่างเก็บน้ำประแสร์

ข้อมูลเบื้องต้นของกลุ่มน้ำ มีดังนี้

พื้นที่ลุ่มน้ำปราจีนบุรีด้านเหนืออ่างเก็บน้ำประแสร์เป็นทิวเขาสูง มีลุ่มน้ำย่อยๆ และในช่วงฤดูฝนมีน้ำท่วมเป็นประจำ กรมชลประทานจึงก่อสร้างอ่างเก็บน้ำประแสร์เพื่อบรรเทาปัญหาดังกล่าว รวมถึงวัตถุประสงค์เพื่อการชลประทาน ข้อมูลเบื้องต้นที่จะนำมาใช้ในแบบจำลอง มีดังนี้

พื้นที่ลุ่มน้ำ 1,280 ตร.กม.

- สถานีวัดน้ำฝนที่นำมาใช้
1. สถานีบ้านจ๊กโกรก (Z-11)
 2. สถานีบ้านจั่นค้อ (Z-18)
 3. สถานีวังจั่น

สถานีวัดน้ำท่าที่นำมาใช้ สถานีบ้านจ๊กโกรก (Z-11)

ช่วงฝึกแบบจำลอง (Calibration Period หรือ Training Phase) 3 ปี คือ ปี ค.ศ. 2538-2540

ช่วงทดสอบแบบจำลอง (Verification Period หรือ Testing Phase) 2 ปี คือ ปี ค.ศ. 2536-2537

โครงสร้างของแบบจำลอง ANN ที่ดีที่สุด 3-Layers Neural Network

แบบจำลอง ANN ที่ใช้ winNN97


(<http://www.impex.msk.ru/finance/analyst/demo.htm>)

- ข้อมูลนำเข้าที่ดีที่สุด
1. ฝนเฉลี่ยจากสถานี Z-11 และ Z-18 ที่ตกในลุ่มน้ำ ย้อนหลังไป 2 วัน (2 lag time)
 2. ปริมาณน้ำสถานีบ้านจ๊กโกรก (Z-11) ย้อนหลัง 3 วัน

หลักการเบื้องต้น

1. ทำการคำนวณฝนเฉลี่ยจากสถานีวัดน้ำฝน 3 สถานี โดยวิธีหาค่าเฉลี่ยน้ำหนักของสถานีวังจั่น สถานีบ้านจ๊กโกรกและสถานีบ้านจั่นค้อ เท่ากับ 0.63, 0.03 และ 0.34 ตามลำดับ
 2. เลือกข้อมูลนำเข้า ซึ่งขึ้นอยู่กับข้อมูลในอดีตที่มี ในตัวอย่างนี้มีปริมาณน้ำไหลเข้าอ่างที่เก็บได้จาก สถานีบ้านจ๊กโกรก และฝนเหนือจุดพิจารณา 3 สถานี เทคนิคการเลือกข้อมูลนำเข้ากับ Lag Time (ข้อมูลย้อนหลังกี่วัน) นั้น สามารถทำได้โดยการหาค่า Correlation (r) ระหว่างตัวแปรนำเข้ากับ ค่าพยากรณ์ ณ ช่วง Lag Time ต่างๆ เช่น หาค่า r ระหว่าง $Q(t)$ กับ $Q(t+1)$, $Q(t-1)$ กับ $Q(t+1)$ ถ้าค่า r ของความสัมพันธ์คู่ใดมีค่าสูง (ใกล้ 1) แสดงว่ามีความสัมพันธ์กันดี เหมาะกับการนำมาใช้เป็นค่า นำเข้าแบบจำลอง โดยทฤษฎีแล้วไม่ควรเลือกข้อมูลนำเข้าหลายตัวมากเกินไปเพื่อให้แบบจำลอง ทำงานได้มีประสิทธิภาพ
- จากตัวอย่างนี้ ใช้ข้อมูลฝนเฉลี่ยย้อนหลัง 2 วัน ข้อมูลปริมาณน้ำย้อนหลัง 3 วัน เนื่องจากให้ผลการ ฝึกและทดสอบดีที่สุด

3. กำหนดโครงสร้างของ ANN เบื้องต้น ปกติกำหนดแบบ 3 Layers (Input, Hidden และ Output)
 กำหนด Node ของ Hidden Layer (ปกติจะสัมพันธ์ค่าใกล้เคียงกับ จำนวนข้อมูลนำเข้า)
 จากตัวอย่างนี้ จะใช้ Input Node จำนวน 6 Nodes และ Hidden Node 6 Nodes เช่นกัน ซึ่ง
 เรียกว่าโครงสร้าง ANN แบบ 5-5-1 (จะไม่นับ Bias, b) ดังแสดงในรูป 3-2



รูปที่ 3-2 โครงสร้างของ ANN 5-5-1

ดังนั้น ความสัมพันธ์ของแบบจำลอง คือ

$$Q(t+1) = f[R(t)\text{mean area}, R(t-1)\text{mean area}, Q(t), Q(t-1), Q(t-2)]$$

โดยที่

f เป็นความสัมพันธ์แบบไม่เป็นเส้นตรง

$Q(t+1)$ = ปริมาณน้ำที่จะพยากรณ์ล่วงหน้า 1 วัน

$Q(t)$ = ปริมาณน้ำที่วัดได้จริงวันนี้ ที่สถานีบ้านจ๊กโกรก

$Q(t-1)$ = ปริมาณน้ำที่วัดได้จริงเมื่อวานนี้ ที่สถานีบ้านจ๊กโกรก

$Q(t-2)$ = ปริมาณน้ำที่วัดได้จริงเมื่อวานขึ้น ที่สถานีบ้านจ๊กโกรก

$R(t)\text{mean area}$ = ปริมาณฝนเฉลี่ยของ 3 สถานี ที่วัดได้วันนี้

$R(t-1)\text{mean area}$ = ปริมาณฝนเฉลี่ยของ 3 สถานี ที่วัดได้เมื่อวานนี้

4. Data Pre-Processing

ข้อดีของแบบจำลอง ANN คือหน่วยของข้อมูลนำเข้าแตกต่างกันได้ เช่น ปริมาณน้ำเป็น ลบม./วินาที ปริมาณฝนเป็น มิลลิเมตร เป็นต้น แต่จำเป็นต้องมีการแปลงค่าตัวเลขของข้อมูลนำเข้าดังกล่าวก่อนให้อยู่ในช่วง 0-1 ก่อน โดยใช้สมการ

$$y_t = \frac{[(b-a)(y'_t - a)]}{0.9} + a$$

โดยที่ y_t = ค่าจริง

a = ค่าต่ำสุดที่ได้

b = ค่าสูงสุดที่ได้

y'_t = ค่าที่ใช้ปรับ (ได้จากขั้นตอน Data Pre-Processing)

5. Data Post-Processing

หลังจากที่ได้โครงสร้างแบบจำลอง ANN ที่ดีที่สุดแล้ว ผลการพยากรณ์จะถูกแปลค่ากลับจากช่วง 0-1 มาเป็นค่าเดิม โดยใช้สมการ

$$y'_t = \frac{[0.9(y_t - a)]}{b - a} + 0.05$$

6. ค่าถ่วงน้ำหนักและค่า Bias เริ่มต้น (Initial weights and Bias)

คอมพิวเตอร์จะสุ่มค่าถ่วงน้ำหนักโดยเริ่มต้นจากค่าน้อยทั้งค่า + และ - และจะสุ่มปรับค่าอยู่ระหว่างค่า -3 ถึง + 3 โดยผลรวมของค่าถ่วงน้ำหนักจะมีค่าใกล้ 0 เพื่อให้การเรียนรู้ของ ANN เร็วขึ้น

7. ข้อกำหนดในการให้แบบจำลอง ANN หยุดทำงาน

แบบจำลองจะหยุดทำงานเมื่อค่าแตกต่างระหว่างผลรวมของค่าพยากรณ์และค่าจริงมีค่าน้อยกว่าค่าที่กำหนด (Target error) ปกติจะกำหนดค่าแตกต่างไม่เกิน 5 %


8. Learning Rate (LR) และ Momentum Rate (MR)

ค่า Learning Rate (LR) จะมีผลต่อการเปลี่ยนแปลงค่าถ่วงน้ำหนักระหว่าง node ถ้าค่า LR สูง จะทำให้การ Run แบบจำลองจบเร็วขึ้น แต่ถ้าสูงมากเกินไปจะเกิดการแกว่งของผลค่าแตกต่างระหว่าง ค่าพยากรณ์กับค่าจริงที่ได้ คือ ค่าแตกต่างจะไม่ลดน้อยลงเรื่อยๆ แบบที่ควรจะเป็น ซึ่ง Rumelhart และ คณะ (1986) ได้แก้ปัญหการแกว่งขึ้นลงนี้โดยกำหนดค่า Momentum Rate (MR) ขึ้นมา

ปัญหาของการใช้แบบจำลอง ANNs คือการหาค่า LR และ MR ที่เหมาะสมซึ่งจำเป็นต้องใช้ วิธีการ Trial and error โดยทั่วไปค่า LR จะอยู่ระหว่าง 0.01-1.0 และค่า MR จะอยู่ระหว่าง 0-1


8. การทำงานของ ANN แบบวิธี Back Propagation

ขั้นตอนการทำงานของแบบจำลอง ANN แบบวิธี Back Propagation แสดงในรูป 3-3



รูปที่ 3-3 ขั้นตอนการทำงานของ Back Propagation Neural Model

และผังแสดงการทำงานแบบ Back Propagation โดยละเอียดแสดงดังรูป 3-4



รูปที่ 3-4 ผังการทำงานแบบ Back Propagation สำหรับการฝึกและทดสอบแบบจำลอง ANNs

ขั้นตอนการทำงานโดยละเอียดโดยวิธี Back Propagation ในช่วงของการฝึก มีดังนี้

1. คอมพิวเตอร์กำหนดค่าถ่วงน้ำหนักและค่า bias factors (เริ่มจากค่าน้อยๆ) และเริ่มการคำนวณไปข้างหน้า (Forward pass)
2. กำหนดให้ข้อมูลนำเข้าคือ $I_1, I_2, \dots, I_n$ และกำหนดผลการพยากรณ์คือ $t_1, t_2, \dots, t_n$
3. สำหรับ Layer $m = 1, 2, \dots, l$
 - ก. คำนวณหาค่าของ node ใน Hidden Layer ถัดไปจากสมการ

$$N_{j,m} = \sum_{i=1}^{n_{m-1}} (W_{ji,m} \cdot O_{i,m-1}) + \theta_{j,m}$$

โดยที่

$$O_{i,0} = I_i$$

- ข. คำนวณหาค่าของผลการพยากรณ์ที่ได้จาก node j_{th} ใน Layer m จากสมการ

$$O_{j,m} = \frac{1}{1 + e^{-N_{j,m}}}; j = 1, 2, \dots, n_m$$

4. เปรียบเทียบค่าพยากรณ์สุดท้าย ($O_{1,1}, O_{2,1}, \dots, O_{n_1,1}$) กับค่าจริง ($t_1, t_2, \dots, t_{n_1}$) ถ้าค่าที่พยากรณ์ต่างจากค่าจริงไม่เกินเกณฑ์ที่กำหนด (ปกติต่างกันไม่เกิน 5%) หรือรอบที่วิ่งไปกลับเกินค่าที่กำหนด แบบจำลองจะหยุดคำนวณและจะจำค่าถ่วงน้ำหนักฯ ไว้
- ถ้าค่าแตกต่างยังเกินเกณฑ์ดังกล่าว แบบจำลองจะคำนวณย้อนกลับ (Backward pass) เพื่อปรับแก้ค่าถ่วงน้ำหนัก

5. ในการคำนวณย้อนกลับ (Backward pass) เพื่อปรับแก้ค่าถ่วงน้ำหนัก จะเริ่มจาก layer $m=l, l-1, l-2, \dots, 1$

ก. หาค่า

สำหรับ layer m ของ output layer

$$\delta_{j,m} = O_{j,m}(1 - O_{j,m})(t_j - O_{j,m})$$

สำหรับ layer m ของ hidden layer

$$\delta_{j,m} = O_{j,m}(1 - O_{j,m}) \sum_{k=1}^{n_{m+1}} W_{kj,m+1} \delta_{k,m+1}$$

ข. คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนัก จากสมการ

$$\Delta W_{ji,m}(n+1) = \eta \cdot \delta_{j,m} \cdot O_{i,m-1} + \alpha \cdot \Delta W_{ji,m}(n)$$

โดยที่ n คือจำนวนรอบสุดท้ายที่แบบจำลองทำงาน

ค. คำนวณค่าถ่วงน้ำหนักใหม่จากสมการ

$$W_{ji,m}(n+1) = W_{ji,m}(n) + \Delta W_{ji,m}(n+1)$$


6. กลับไปยังขั้นตอนที่ 2

คำอธิบายตัวแปรต่างๆ

t_j	=	ค่าปริมาณน้ำจริงที่เก็บได้ ของ node j ใน output layer
$O_{j,m}$	=	ค่า Output ของ node j ใน layer m

$N_{j,m}$	=	โครงข่ายของ node j ใน layer m
$O_{j,m}$	=	ค่า bias สำหรับ node j ใน layer m
LR	=	learning parameter
MR	=	momentum parameter
$W_{ji,m}(n)$	=	ค่าถ่วงน้ำหนัก ของใยประสาทที่เชื่อมระหว่าง node j ใน layer m กับ node i ที่ รอบการคำนวณที่ n
$W_{ji,m}(n+1)$	=	ค่าถ่วงน้ำหนัก ของใยประสาทที่เชื่อมระหว่าง node j ใน layer m กับ node i ที่ รอบการคำนวณที่ n+1
$W_{ji,m}(n)$	=	ค่าปรับแก้ค่าถ่วงน้ำหนัก ของใยประสาทที่เชื่อมระหว่าง node j ใน layer m กับ node i ที่ รอบการคำนวณที่ n
$W_{ji,m}(n+1)$	=	ค่าปรับแก้ค่าถ่วงน้ำหนัก ของใยประสาทที่เชื่อมระหว่าง node j ใน layer m กับ node i ที่ รอบการคำนวณที่ n+1
$O_{j,m}$	=	$I_{i,m}$
n	=	รอบการคำนวณ (เริ่มจากรอบที่ 1 ถึง n)

ตัวแปรต่างๆ แสดงดังรูป 3-5



รูปที่ 3-5 ตัวแปรต่างๆ ในโครงข่าย ANN

ถอดรหัส

5-5-1 Neural Network ซึ่งประกอบด้วยข้อมูลนำเข้า 5 ตัว และมี 5 node ในชั้นของ hidden layer และมี Output 1 ตัว คือปริมาณน้ำที่พยากรณ์ล่วงหน้า 1 วัน และมีข้อมูลนำเข้าแสดงในตารางที่ 3-1

ตารางที่ 3-1 ข้อมูลนำเข้าวันที่ 1-5 พฤษภาคม 2538

วันที่	Pattern	ข้อมูลนำเข้า (Input Data)					Q จริงพ่วงนี้ (target) Q_{t+1}
		ฝนวันนี้ R_t	ฝนเมื่อวาน R_{t-1}	Q วันนี้ Q_t	Q เมื่อวาน Q_{t-1}	Q เมื่อวานขึ้น Q_{t-2}	
		Input 1	Input 2	Input 3	Input 4	Input 5	
1 พ.ค. 2538	1	9.050	0.000	3.890	6.620	0.290	3.110
2 พ.ค. 2538	2	0.000	9.050	3.110	3.890	6.620	1.780
3 พ.ค. 2538	3	0.580	0.000	1.780	3.110	3.890	1.620
4 พ.ค. 2538	4	30.980	0.580	1.620	1.780	3.110	1.160
5 พ.ค. 2538	5	1.600	30.980	1.160	1.620	1.780	1.940

จากสมการ

$$y'_t = \frac{[0.9(y_t - a)]}{b - a} + 0.05$$

จะเห็นได้ว่า

ค่าสูงสุด (b) ของ input และ target เท่ากับ 30.980

ค่าต่ำสุด (a) ของ input และ target เท่ากับ 0.000

เริ่มขั้นตอน Data Pre-processing สำหรับ input 1 วันที่ 1 พ.ค. 2538 (Pattern 1) $R_t = y_t = 9.050$

แทนค่าลงในสมการ จะได้ค่าที่แปลง (normalized data) หรือ $y'_t = 0.312912$

ค่าที่แปลงสำหรับ pattern และ input ต่างๆ แสดงในตารางที่ 3-2

ตารางที่ 3-2 ค่าที่แปลงสำหรับ pattern และ input ต่างๆ


วันที่	Pattern	ข้อมูลนำเข้า (Input Data)					Q จริงพ่วงนี้ (target) Q_{t+1}
		ฝนวันนี้ R_t	ฝนเมื่อวาน R_{t-1}	Q วันนี้ Q_t	Q เมื่อวาน Q_{t-1}	Q เมื่อวานขึ้น Q_{t-2}	
		Input 1	Input 2	Input 3	Input 4	Input 5	
1 พ.ค. 2538	1	0.313	0.050	0.163	0.242	0.058	0.140
2 พ.ค. 2538	2	0.050	0.313	0.140	0.163	0.242	0.102
3 พ.ค. 2538	3	0.067	0.050	0.102	0.140	0.163	0.097
4 พ.ค. 2538	4	0.950	0.067	0.097	0.102	0.140	0.084
5 พ.ค. 2538	5	0.096	0.950	0.084	0.097	0.102	0.106

จากนั้น แบบจำลองจะหาค่าถ่วงน้ำหนักที่อยู่ที่ยู่ประสาทระหว่าง node ต่างๆ และ biases (หาค่าอยู่ระหว่าง +3) ดังแสดงในตารางที่ 3-3

ตารางที่ 3-3 ค่าถ่วงน้ำหนักเชื่อมระหว่าง node ต่างๆ และ biases ที่ได้จากแบบจำลอง

ใยประสาท จาก	Hidden 1					
	Node 1	Node 2	Node 3	Node 4	Node 5	Output
Input 1	-1.50	2.50	1.50	0.22	0.78	
Input 2	1.00	-0.23	-1.50	-1.27	0.65	
Input 3	0.15	0.12	2.40	1.50	-0.55	
Input 4	0.25	0.25	-2.40	-1.23	-0.45	
Input 5	-2.14	-0.22	0.12	0.12	1.00	
Hidden 1						-0.15
Hidden 2						0.35
Hidden 3						-0.25
Hidden 4						1.00
Hidden 5						2.25
	Node 1	Node 2	Node 3	Node 4	Node 5	Output
Bias	0.24	-0.50	-0.60	0.47	0.50	-0.23

ตัวอย่างแสดงค่าต่างๆ ดังรูป



รูปที่ 3-6 แสดงค่าต่างๆ ในโครงข่าย ANN

เริ่มคำนวณไปข้างหน้า (Forward Pass)

วันที่ 1 พ.ค. 2538 (Pattern 1)

สำหรับ Hidden Layer 1, Node 1

(Input 1 * ค่าถ่วงน้ำหนักระหว่าง input 1 กับ node 1)	$= (0.313) * (-1.5)$	$= -0.469$
(Input 2 * ค่าถ่วงน้ำหนักระหว่าง input 2 กับ node 1)	$= (0.050) * (1.000)$	$= 0.050$
(Input 3 * ค่าถ่วงน้ำหนักระหว่าง input 3 กับ node 1)	$= (0.163) * (0.150)$	$= 0.024$
(Input 4 * ค่าถ่วงน้ำหนักระหว่าง input 4 กับ node 1)	$= (0.242) * (0.250)$	$= 0.060$
(Input 5 * ค่าถ่วงน้ำหนักระหว่าง input 5 กับ node 1)	$= (0.058) * (-2.140)$	$= -0.125$
(bias ไปยัง Hidden 1)	$= 0.240$	$= 0.240$


โครงข่ายประสาท 1 (Net 1) สำหรับ Node 1 ใน Hidden 1

$$\begin{aligned}
 &= (-0.469) + (0.05) + (0.024) + (0.060) + (-0.125) + (0.240) \\
 &= -0.219
 \end{aligned}$$

ใช้ Transfer function, $f(\text{Net } 1) = 1/(1+e^{-(\text{net}1)})$ ในการแปลงสำหรับ Hidden Node 1

$$\begin{aligned}
 &= 1/(1+2.718^{-(0.219)}) \\
 &= 0.445
 \end{aligned}$$

ใส่ผลการคำนวณจาก Input 1 ถึง 5 ไปยัง node 1 ของ Hidden layer 1 ดังแสดงในรูปที่ 3-7



รูปที่ 3-7 ผลการคำนวณจาก Input 1 ถึง 5 ไปยัง node 1, Hidden 1

Hidden 1, node 2

(Input 1 * ค่าถ่วงน้ำหนักระหว่าง input 1 กับ node 2)	$= (0.313) * (2.50)$	$= 0.782$
(Input 2 * ค่าถ่วงน้ำหนักระหว่าง input 2 กับ node 2)	$= (0.050) * (-0.23)$	$= -0.011$
(Input 3 * ค่าถ่วงน้ำหนักระหว่าง input 3 กับ node 2)	$= (0.163) * (0.120)$	$= 0.019$
(Input 4 * ค่าถ่วงน้ำหนักระหว่าง input 4 กับ node 2)	$= (0.242) * (0.250)$	$= 0.060$
(Input 5 * ค่าถ่วงน้ำหนักระหว่าง input 5 กับ node 2)	$= (0.058) * (-0.220)$	$= -0.013$
(bias ไปยัง Hidden 1)	$= -0.500$	$= -0.500$

โครงข่ายประสาท 2 (Net 2) สำหรับ Node 2 ใน Hidden 1

$$= (0.782)+(-0.011)+(0.190)+(0.060)+(-0.120)+(-0.500)$$


$$= 0.338$$

ใช้ Transfer function, $f(\text{Net } 1) = 1/(1+e^{(-\text{net}2)})$ ในการแปลงสำหรับ Output ใน Hidden Node 1

$$= 1/(1+2.718^{(-0.338)})$$

$$= 0.584$$

ใส่ผลการคำนวณจาก Input 1 ถึง 5 ไปยัง node 2 ของ Hidden layer 1 ดังแสดงในรูป 3-8



รูปที่ 3-8 ผลการคำนวณจาก Input 1 ถึง 5 ไปยัง node 2, Hidden 1


แบบจำลองจะคำนวณเช่นนี้ต่อไปสำหรับ node 3 จนถึง node 5 ได้ผลดังนี้

Output ใน node 3 = 0.404

Output ใน node 4 = 0.605

Output ใน node 5 = 0.654

สรุปผลได้ ดังรูป 3-9



รูปที่ 3-9 ผลการคำนวณใน Layer ต่างๆ

จากนั้น แบบจำลองจะคำนวณไปข้างหน้าสำหรับ Output layer ซึ่งจะเป็น node แสดงผลการพยากรณ์จากแบบจำลอง

จาก Hidden Layer 1 ไปยัง Output layer

$$\begin{aligned}
 (\text{node 1} * \text{ค่าถ่วงน้ำหนักระหว่าง node 1 กับ Output}) &= (0.445) * (-0.15) &= -0.067 \\
 (\text{node 2} * \text{ค่าถ่วงน้ำหนักระหว่าง node 2 กับ Output}) &= (0.584) * (0.35) &= 0.204 \\
 (\text{node 3} * \text{ค่าถ่วงน้ำหนักระหว่าง node 3 กับ Output}) &= (0.404) * (-0.25) &= -0.101 \\
 (\text{node 4} * \text{ค่าถ่วงน้ำหนักระหว่าง node 4 กับ Output}) &= (0.605) * (1.00) &= 0.605 \\
 (\text{node 5} * \text{ค่าถ่วงน้ำหนักระหว่าง node 5 กับ Output}) &= (0.654) * (2.25) &= 1.471 \\
 (\text{bias ไปยัง Output}) &= -0.23 &= -0.23
 \end{aligned}$$

รวมโครงข่ายใยประสาท สำหรับ Output

$$= (-0.066) + (0.204) + (-0.100) + (0.605) + (1.471) + (-0.230)$$


$$= 1.883$$

ใช้ Transfer function, $f(\text{Net } 1) = 1/(1+e^{(-\text{net}2)})$ ในการแปลงค่า Output

$$= 1/(1+2.718^{(-1.883)})$$

$$= 0.868$$

ผลการคำนวณจาก Hidden Layer 1 จาก node 1 ถึง 5 ไปยัง Output แสดงในรูป 3-10



รูปที่ 3-10 ผลการคำนวณจาก node ต่างๆ ใน Hidden Layer ไปยัง Output

จากนั้นจะเป็นการเปรียบเทียบผลการพยากรณ์ของแบบจำลองกับค่าปริมาณน้ำจริงที่ไหลลงอ่างเก็บน้ำรุ่งขึ้น (วันที่ 2 พ.ค. 2538 ปริมาณน้ำจริงที่ไหลลงอ่างฯ ที่ Normalized แล้ว เท่ากับ 0.140)


$$\text{ค่าแตกต่าง} = (\text{ค่าจริง} - \text{ค่าพยากรณ์}) = (0.140 - 0.868) = -0.728$$

$$(\text{ค่าจริง} - \text{ค่าพยากรณ์})^2 = (-0.728)^2 = 0.529$$

$$\text{ค่าผิดพลาดที่ยอมรับได้ } 5\% = 0.05$$

จะเห็นว่า ค่าแตกต่าง > ค่าผิดพลาดที่ยอมให้ ($0.529 > 0.05$)

จากนั้นจะคำนวณไปข้างหน้าต่อไปสำหรับวันเริ่มต้น วันที่ 2 พ.ค. 2538 (Pattern 2) ได้ผลดังแสดง
ในรูป 3-11



รูปที่ 3-11 ผลการคำนวณสำหรับวันเริ่มต้นวันที่ 2 พ.ค. 2538 (Pattern 2)

และเปรียบเทียบผลการพยากรณ์ของแบบจำลองกับค่าปริมาณน้ำจริงที่ไหลลง อ่างเก็บน้ำรุ่ง
จีน (วันที่ 3 พ.ค. 2538 ปริมาณน้ำจริงที่ไหลลงอ่างฯ ที่ Normalized แล้ว เท่ากับ 0.102)


$$\text{ค่าแตกต่าง} = (\text{ค่าจริง} - \text{ค่าพยากรณ์}) = (0.102 - 0.871) = -0.770$$

$$(\text{ค่าจริง} - \text{ค่าพยากรณ์})^2 = (-0.770)^2 = 0.592$$

$$\text{ค่าผิดพลาดที่ยอมให้ } 5\% = 0.05$$

จะเห็นว่า ค่าแตกต่าง > ค่าผิดพลาดที่ยอมให้ ($0.592 > 0.05$)

จากนั้นจะคำนวณไปข้างหน้าต่อไปสำหรับวันเริ่มต้น วันที่ 3 พ.ค. 2538 (Pattern 3) ได้ผลดังแสดง



ผังรูป 3-12

รูปที่ 3-12 ผลการคำนวณสำหรับวันเริ่มต้นวันที่ 3 พ.ค. 2538 (Pattern 3)

และการเปรียบเทียบผลการพยากรณ์ของแบบจำลองกับค่าปริมาณน้ำจริงที่ไหลลง อ่างเก็บน้ำ รุ่งขึ้น (วันที่ 4 พ.ค. 2538 ปริมาณน้ำจริงที่ไหลลงอ่างฯ ที่ Normalized แล้ว เท่ากับ 0.097)


$$\text{ค่าแตกต่าง} = (\text{ค่าจริง} - \text{ค่าพยากรณ์}) = (0.097 - 0.862) = -0.765$$

$$(\text{ค่าจริง} - \text{ค่าพยากรณ์})^2 = (-0.765)^2 = 0.585$$

$$\text{ค่าผิดพลาดที่ยอมให้ 5 \%} = 0.05$$

จะเห็นว่า ค่าแตกต่าง > ค่าผิดพลาดที่ยอมให้ ($0.585 > 0.05$)

จากนั้นจะคำนวณไปข้างหน้าต่อไปสำหรับวันเริ่มต้น วันที่ 4 พ.ค. 2538 (Pattern 4) ได้ผลดังแสดง ในรูปที่ 3-13




รูปที่ 3-13 ผลการคำนวณสำหรับวันเริ่มต้นวันที่ 4 พ.ค. 2538 (Pattern 4)

และเปรียบเทียบผลการพยากรณ์ของแบบจำลองกับค่าปริมาณน้ำจริงที่ไหลลง อ่างเก็บน้ำรุ่ง
จีน (วันที่ 5 พ.ค. 2538 ปริมาณน้ำจริงที่ไหลลงอ่างฯ ที่ Normalized แล้ว เท่ากับ 0.084)

$$\begin{aligned} \text{ค่าแตกต่าง} &= (\text{ค่าจริง} - \text{ค่าพยากรณ์}) = (0.084 - 0.909) &= -0.825 \\ (\text{ค่าจริง} - \text{ค่าพยากรณ์})^2 &= (-0.825)^2 &= 0.681 \\ \text{ค่าผิดพลาดที่ยอมรับได้ 5 \%} & &= 0.05 \end{aligned}$$

จะเห็นว่า ค่าแตกต่าง > ค่าผิดพลาดที่ยอมรับได้ ($0.681 > 0.05$)
จากนั้นจะคำนวณไปข้างหน้าต่อไปสำหรับวันเริ่มต้น วันที่ 5 พ.ค. 2538 (Pattern 5) ได้ผลดังแสดง
ในรูปที่ 3-14



รูปที่ 3-14 ผลการคำนวณสำหรับวันเริ่มต้นวันที่ 5 พ.ค. 2538 (Pattern 5)

และเปรียบเทียบผลการพยากรณ์ของแบบจำลองกับค่าปริมาณน้ำจริงที่ไหลลง อ่างเก็บน้ำรุ่ง
จีน (วันที่ 6 พ.ค. 2538 ปริมาณน้ำจริงที่ไหลลงอ่างฯ ที่ Normalized แล้ว เท่ากับ 0.106)

$$\text{ค่าแตกต่าง} = (\text{ค่าจริง} - \text{ค่าพยากรณ์}) = (0.106 - 0.862) = -0.756$$

$$(\text{ค่าจริง} - \text{ค่าพยากรณ์})^2 = (-0.756)^2 = 0.571$$

$$\text{ค่าผิดพลาดที่ยอมรับให้ 5 \%} = 0.05$$

จะเห็นว่า ค่าแตกต่าง > ค่าผิดพลาดที่ยอมรับให้ ($0.571 > 0.05$)

เมื่อสิ้นสุดทุก Pattern แล้วจึงคำนวณผลรวมค่าแตกต่าง (Sum of square error) หรือ Sum(ค่าจริง – ค่าพยากรณ์)² ของทุก Patterns

$$= (0.529 + 0.592 + 0.585 + 0.681 + 0.571)$$

$$= 2.959$$

$$\text{Mean square error} = 2.959/5$$

$$= 0.592$$

ผลรวม error ทั้งหมด (Root Mean Square Error; RMSE) ทุกๆ ประสาท = (Mean square error)^{1/2}

$$= 0.592^{1/2}$$

$$= 0.769$$

ค่าผิดพลาดที่ยอมรับให้ 5 % = 0.05

จะเห็นว่า $RMSE > 0.05$ จึงต้องคำนวณในขั้นตอนคำนวณย้อนกลับเพื่อปรับแก้ค่าถ่วงน้ำหนักต่อไป

ขั้นตอนคำนวณย้อนกลับเพื่อปรับแก้ค่าถ่วงน้ำหนัก

กำหนดค่า Learning Rate (LR) = 0.03 (มีค่าระหว่าง 0.01-1.00)

 Momentum Rate (MR) = 0.50 (มีค่าระหว่าง 0-1.00)

การคำนวณย้อนกลับรอบที่ 1 (Iteration 1)

สำหรับ Pattern 1 (เริ่ม 1 พ.ค. 2538)

Output Layer

t = target (ค่าจริงที่ต้องการ) และ O = output (ผลการพยากรณ์จากแบบจำลอง หน้า 43)

$$(t-O) = (0.140)-(0.868) = -0.728$$

$$O(1-O) = (0.868)*(1-0.868) = 0.114$$

$$\text{Delta} = (t-O)O(1-O) = (-0.728)*(0.114) = -0.083$$

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Hidden node กับ Output (Weight change = LR*delta*Output from hidden node หน้า 43)

$$\text{Weight change ระหว่าง output กับ hidden node 1} = (0.03)*(-0.083)*(0.445) = -0.0011$$

$$\text{Weight change ระหว่าง output กับ hidden node 2} = (0.03)*(-0.083)*(0.584) = -0.0015$$


Weight change ระหว่าง output กับ hidden node 3 = $(0.03)*(-0.083)*(0.403) = -0.0010$

Weight change ระหว่าง output กับ hidden node 4 = $(0.03)*(-0.083)*(0.605) = -0.0015$

Weight change ระหว่าง output กับ hidden node 5 = $(0.03)*(-0.083)*(0.654) = -0.0016$


Bias change (LR * delta) = $(0.03)*(-0.083) = -0.0025$

ผลการคำนวณแสดงในรูป 3-15



รูปที่ 3-15 แสดงการคำนวณย้อนกลับเพื่อปรับแก้ค่าถ่วงน้ำหนักจาก node 1, Hidden 1 ไปยัง Input ต่างๆ

ผลการคำนวณจาก Output ไปยัง Hidden Layer 1 แสดงในรูปที่ 3-16



รูปที่ 3-16 ผลการคำนวณค่าปรับแก้ค่าถ่วงน้ำหนักจาก Output กระจายกลับไปยัง Hidden Layer

Hidden Layer

O = Output จาก hidden node

Hidden node 1 (จากหน้า 45 , O = 0.4451)

$$O(1-O) = (0.445)*(1-0.445) = 0.247$$

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Input node ต่างๆ ไปยัง Hidden node 1 (Weight change = LR*delta* input node to hidden node)

$$\begin{aligned} \text{Delta สำหรับ hidden node 1} &= \text{Delta (หน้า 49) * Weight * O(1-O)} \\ &= (-0.083) * (-0.15) * (0.247) \\ &= 0.003 \end{aligned}$$

$$\text{Weight change ระหว่าง input 1 กับ hidden node 1} = (0.03) * (0.003) * (0.313) = 0.000029$$

$$\text{Weight change ระหว่าง input 2 กับ hidden node 1} = (0.03) * (0.003) * (0.050) = 0.000005$$

$$\text{Weight change ระหว่าง input 3 กับ hidden node 1} = (0.03) * (0.003) * (0.163) = 0.000015$$

Weight change ระหว่าง input 4 กับ hidden node 1 = $(0.03)*(0.003)*(0.242) = 0.000022$

Weight change ระหว่าง input 5 กับ hidden node 1 = $(0.03)*(0.003)*(0.058) = 0.000005$

Bias change (LR * delta) = $(0.03)*(0.003) = 0.000093$

Hidden node 2

$$O(1-O) = (0.584)*(1-0.584) = 0.243$$

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Input node ต่างๆ ไปยัง Hidden node 2 (Weight change = LR*delta* input node to hidden node)

$$\begin{aligned}\text{Delta สำหรับ hidden node 2} &= (-0.083)*(0.243)*(0.35) \\ &= -0.007\end{aligned}$$

Weight change ระหว่าง input 1 กับ hidden node 2 = $(0.03)*(-0.007)*(0.313) = -0.000067$

Weight change ระหว่าง input 2 กับ hidden node 2 = $(0.03)*(-0.007)*(0.050) = -0.000011$

Weight change ระหว่าง input 3 กับ hidden node 2 = $(0.03)*(-0.007)*(0.163) = -0.000035$

Weight change ระหว่าง input 4 กับ hidden node 2 = $(0.03)*(-0.007)*(0.242) = -0.000052$

Weight change ระหว่าง input 5 กับ hidden node 2 = $(0.03)*(-0.007)*(0.058) = -0.000012$

Bias change (LR * delta) = $(0.03)*(-0.007) = -0.000213$

จากนั้นก็คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Input node ต่างๆ ไปยัง Hidden node 3, 4, 5 ตามลำดับ สำหรับ Pattern 1 (เริ่ม 1 พ.ค.) ด้วยวิธีการเดียวกัน ได้ผลดังแสดง

Hidden node 3

Input node ต่างๆ ไปยัง Hidden node 3

Weight change ระหว่าง input 1 กับ hidden node 3 = 0.000047

Weight change ระหว่าง input 2 กับ hidden node 3 = 0.000008

Weight change ระหว่าง input 3 กับ hidden node 3 = 0.000025

Weight change ระหว่าง input 4 กับ hidden node 3 = 0.000036

Weight change ระหว่าง input 5 กับ hidden node 3 = 0.000009

Bias change (LR * delta) = 0.000151

Hidden node 4

Input node ต่างๆ ไปยัง Hidden node 4

Weight change ระหว่าง input 1 กับ hidden node 4 = -0.000187

Weight change ระหว่าง input 2 กับ hidden node 4 = -0.000030

Weight change ระหว่าง input 3 กับ hidden node 4 = -0.000097

Weight change ระหว่าง input 4 กับ hidden node 4 = -0.000145

Weight change ระหว่าง input 5 กับ hidden node 4 = -0.000035

Bias change (LR * delta) = -0.000597

Hidden node 5

Input node ต่างๆ ไปยัง Hidden node 5

Weight change ระหว่าง input 1 กับ hidden node 5 = -0.000399

Weight change ระหว่าง input 2 กับ hidden node 5 = -0.000064

Weight change ระหว่าง input 3 กับ hidden node 5 = -0.000208

Weight change ระหว่าง input 4 กับ hidden node 5 = -0.000309

Weight change ระหว่าง input 5 กับ hidden node 5 = -0.000074

Bias change (LR * delta) = -0.001247

สำหรับ Pattern 2 (เริ่ม 2 พ.ค.) คำนวณค่าปรับแก้ค่าถ่วงน้ำหนักเช่นเดียวกับ Pattern 1 เริ่มจาก

Input node ต่างๆ กับ Hidden node 1, 2, 3, 4, 5 ตามลำดับ ด้วยวิธีการเดียวกัน ได้ผลดังแสดง

Output Layer

t = target (ค่าจริงที่ต้องการ หน้า 38) และ O = output (ผลการพยากรณ์จากแบบจำลอง=0.871 หน้า 45)

$$\begin{aligned}(t-O) &= (0.102)-(0.871) = -0.770 \\ O(1-O) &= (0.871)*(1-0.871) = 0.112 \\ \text{Delta} = (t-O)O(1-O) &= (-0.770)*(0.112) = -0.086\end{aligned}$$

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Hidden node กับ Output (Weight change = LR*delta*Output from hidden node หน้า 45)

Weight change ระหว่าง output กับ hidden node 1 = $(0.03)*(-0.086)*(0.505) = -0.0013$

Weight change ระหว่าง output กับ hidden node 2 = $(0.03)*(-0.086)*(0.391) = -0.0010$

Weight change ระหว่าง output กับ hidden node 3 = $(0.03)*(-0.086)*(0.067) = -0.0002$
 Weight change ระหว่าง output กับ hidden node 4 = $(0.03)*(-0.086)*(0.530) = -0.0014$
 Weight change ระหว่าง output กับ hidden node 5 = $(0.03)*(-0.086)*(0.697) = -0.0018$
 Bias change (LR * delta) = $(0.03)*(-0.083) = -0.0026$

Hidden Layer

O = Output จาก hidden node

Hidden node 1

Input node ต่างๆ ไปยัง Hidden node 1

Weight change ระหว่าง input 1 กับ hidden node 1 = 0.000005
 Weight change ระหว่าง input 2 กับ hidden node 1 = 0.000030
 Weight change ระหว่าง input 3 กับ hidden node 1 = 0.000014
 Weight change ระหว่าง input 4 กับ hidden node 1 = 0.000016
 Weight change ระหว่าง input 5 กับ hidden node 1 = 0.000024
 Bias change (LR * delta) = 0.000097

Hidden node 2

Input node ต่างๆ ไปยัง Hidden node 2

Weight change ระหว่าง input 1 กับ hidden node 2 = -0.000011
 Weight change ระหว่าง input 2 กับ hidden node 2 = -0.000067
 Weight change ระหว่าง input 3 กับ hidden node 2 = -0.000030
 Weight change ระหว่าง input 4 กับ hidden node 2 = -0.000035
 Weight change ระหว่าง input 5 กับ hidden node 2 = -0.000052
 Bias change (LR * delta) = -0.000216

Hidden node 3

Input node ต่างๆ ไปยัง Hidden node 3

Weight change ระหว่าง input 1 กับ hidden node 3 = 0.000002
 Weight change ระหว่าง input 2 กับ hidden node 3 = 0.000013
 Weight change ระหว่าง input 3 กับ hidden node 3 = 0.000006
 Weight change ระหว่าง input 4 กับ hidden node 3 = 0.000007

Weight change ระหว่าง input 5 กับ hidden node 3 = 0.000010

Bias change (LR * delta) = 0.000040

Hidden node 4

Input node ต่างๆ ไปยัง Hidden node 4

Weight change ระหว่าง input 1 กับ hidden node 4 = -0.000032

Weight change ระหว่าง input 2 กับ hidden node 4 = -0.000202

Weight change ระหว่าง input 3 กับ hidden node 4 = -0.000090

Weight change ระหว่าง input 4 กับ hidden node 4 = -0.000105

Weight change ระหว่าง input 5 กับ hidden node 4 = -0.000156

Bias change (LR * delta) = -0.000644

Hidden node 5

Input node ต่างๆ ไปยัง Hidden node 5

Weight change ระหว่าง input 1 กับ hidden node 5 = -0.000061

Weight change ระหว่าง input 2 กับ hidden node 5 = -0.000384

Weight change ระหว่าง input 3 กับ hidden node 5 = -0.000172

Weight change ระหว่าง input 4 กับ hidden node 5 = -0.000200

Weight change ระหว่าง input 5 กับ hidden node 5 = -0.000298

Bias change (LR * delta) = -0.001229

สำหรับ Pattern 3 (เริ่ม 3 พ.ค.) คำนวณค่าปรับแก้ค่าถ่วงน้ำหนักเช่นเดียวกับ Pattern เริ่มจาก Input node ต่างๆ ไปยัง Hidden node 1, 2, 3, 4, 5 ตามลำดับ ด้วยวิธีการเดียวกัน ได้ผลดังแสดง

Output Layer

t = target (ค่าจริงที่ต้องการหน้า 38) และ O = output (ผลการพยากรณ์จากแบบจำลอง หน้า 46)

$$(t-O) = (0.097)-(0.862) = -0.765$$

$$O(1-O) = (0.862)*(1-0.862) = 0.119$$

$$\Delta = (t-O)O(1-O) = (-0.764)*(0.119) = -0.091$$

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Hidden node กับ Output (Weight change = LR*delta*Output from hidden node)

Weight change ระหว่าง output กับ hidden node 1 = $(0.03)*(-0.091)*(0.473) = -0.0013$
 Weight change ระหว่าง output กับ hidden node 2 = $(0.03)*(-0.091)*(0.417) = -0.0011$
 Weight change ระหว่าง output กับ hidden node 3 = $(0.03)*(-0.091)*(0.343) = -0.0009$
 Weight change ระหว่าง output กับ hidden node 4 = $(0.03)*(-0.091)*(0.604) = -0.0016$
 Weight change ระหว่าง output กับ hidden node 5 = $(0.03)*(-0.091)*(0.652) = -0.0018$
 Bias change (LR * delta) = $(0.03)*(-0.091) = -0.0027$

Hidden Layer

O = Output จาก hidden node

Hidden node 1

Input node ต่างๆ ไปยัง Hidden node 1

Weight change ระหว่าง input 1 กับ hidden node 1 = 0.000007
 Weight change ระหว่าง input 2 กับ hidden node 1 = 0.000005
 Weight change ระหว่าง input 3 กับ hidden node 1 = 0.000010
 Weight change ระหว่าง input 4 กับ hidden node 1 = 0.000014
 Weight change ระหว่าง input 5 กับ hidden node 1 = 0.000017
 Bias change (LR * delta) = 0.000102

Hidden node 2

Input node ต่างๆ ไปยัง Hidden node 2

Weight change ระหว่าง input 1 กับ hidden node 2 = -0.000016
 Weight change ระหว่าง input 2 กับ hidden node 2 = -0.000012
 Weight change ระหว่าง input 3 กับ hidden node 2 = -0.000024
 Weight change ระหว่าง input 4 กับ hidden node 2 = -0.000033
 Weight change ระหว่าง input 5 กับ hidden node 2 = -0.000038
 Bias change (LR * delta) = -0.000233

Hidden node 3

Input node ต่างๆ ไปยัง Hidden node 3

Weight change ระหว่าง input 1 กับ hidden node 3 = 0.000010
 Weight change ระหว่าง input 2 กับ hidden node 3 = 0.000008

Weight change ระหว่าง input 3 กับ hidden node 3 = 0.000016
 Weight change ระหว่าง input 4 กับ hidden node 3 = 0.000022
 Weight change ระหว่าง input 5 กับ hidden node 3 = 0.000025
 Bias change (LR * delta) = 0.000154

Hidden node 4

Input node ต่างๆ ไปยัง Hidden node 4

Weight change ระหว่าง input 1 กับ hidden node 4 = -0.000044
 Weight change ระหว่าง input 2 กับ hidden node 4 = -0.000033
 Weight change ระหว่าง input 3 กับ hidden node 4 = -0.000066
 Weight change ระหว่าง input 4 กับ hidden node 4 = -0.000092
 Weight change ระหว่าง input 5 กับ hidden node 4 = -0.000107
 Bias change (LR * delta) = -0.000654

Hidden node 5

Input node ต่างๆ ไปยัง Hidden node 5

Weight change ระหว่าง input 1 กับ hidden node 5 = -0.000093
 Weight change ระหว่าง input 2 กับ hidden node 5 = -0.000070
 Weight change ระหว่าง input 3 กับ hidden node 5 = -0.000142
 Weight change ระหว่าง input 4 กับ hidden node 5 = -0.000196
 Weight change ระหว่าง input 5 กับ hidden node 5 = -0.000227
 Bias change (LR * delta) = -0.001395

สำหรับ Pattern 4 (เริ่ม 4 พ.ค.) คำนวณค่าปรับแก้ค่าถ่วงน้ำหนักเช่นเดียวกับ Pattern เริ่มจาก Input node ต่างๆ ไปยัง Hidden node 1, 2, 3, 4, 5 ตามลำดับ ด้วยวิธีการเดียวกัน ได้ผลดังแสดง

Output Layer

t = target (ค่าจริงที่ต้องการ) และ O = output (ผลการพยากรณ์จากแบบจำลอง)

(t-O) = -0.825
 O(1-O) = 0.082
 Delta = (t-O)O(1-O) = -0.068

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Hidden node กับ Output (Weight change = $LR * \delta * \text{Output from hidden node}$)

Weight change ระหว่าง output กับ hidden node 1 = -0.0004

Weight change ระหว่าง output กับ hidden node 2 = -0.0018

Weight change ระหว่าง output กับ hidden node 3 = -0.0014

Weight change ระหว่าง output กับ hidden node 4 = -0.0013

Weight change ระหว่าง output กับ hidden node 5 = -0.0016

Bias change ($LR * \delta$) = -0.0020

Hidden Layer

O = Output จาก hidden node

Hidden node 1

Input node ต่างๆ ไปยัง Hidden node 1

Weight change ระหว่าง input 1 กับ hidden node 1 = 0.000047

Weight change ระหว่าง input 2 กับ hidden node 1 = 0.000003

Weight change ระหว่าง input 3 กับ hidden node 1 = 0.000005

Weight change ระหว่าง input 4 กับ hidden node 1 = 0.000005

Weight change ระหว่าง input 5 กับ hidden node 1 = 0.000007

Bias change ($LR * \delta$) = 0.000049

Hidden node 2

Input node ต่างๆ ไปยัง Hidden node 2

Weight change ระหว่าง input 1 กับ hidden node 2 = -0.000079

Weight change ระหว่าง input 2 กับ hidden node 2 = -0.000006

Weight change ระหว่าง input 3 กับ hidden node 2 = -0.000008

Weight change ระหว่าง input 4 กับ hidden node 2 = -0.000008

Weight change ระหว่าง input 5 กับ hidden node 2 = -0.000012

Bias change ($LR * \delta$) = -0.000083

Hidden node 3

Input node ต่างๆ ไปยัง Hidden node 3

Weight change ระหว่าง input 1 กับ hidden node 3 = 0.000106
 Weight change ระหว่าง input 2 กับ hidden node 3 = 0.000007
 Weight change ระหว่าง input 3 กับ hidden node 3 = 0.000011
 Weight change ระหว่าง input 4 กับ hidden node 3 = 0.000011
 Weight change ระหว่าง input 5 กับ hidden node 3 = 0.000016
 Bias change (LR * delta) = 0.000112

Hidden node 4

Input node ต่างๆ ไปยัง Hidden node 4

Weight change ระหว่าง input 1 กับ hidden node 4 = -0.000044
 Weight change ระหว่าง input 2 กับ hidden node 4 = -0.000031
 Weight change ระหว่าง input 3 กับ hidden node 4 = -0.000045
 Weight change ระหว่าง input 4 กับ hidden node 4 = -0.000047
 Weight change ระหว่าง input 5 กับ hidden node 4 = -0.000065
 Bias change (LR * delta) = -0.000463

Hidden node 5

Input node ต่างๆ ไปยัง Hidden node 5

Weight change ระหว่าง input 1 กับ hidden node 5 = -0.000724
 Weight change ระหว่าง input 2 กับ hidden node 5 = -0.000051
 Weight change ระหว่าง input 3 กับ hidden node 5 = -0.000074
 Weight change ระหว่าง input 4 กับ hidden node 5 = -0.000078
 Weight change ระหว่าง input 5 กับ hidden node 5 = -0.000107
 Bias change (LR * delta) = -0.000762

สำหรับ Pattern 5 (เริ่ม 5 พ.ค.) คำนวณค่าปรับแก้ค่าถ่วงน้ำหนักเช่นเดียวกับ Pattern เริ่มจาก Input node ต่างๆ ไปยัง Hidden node 1, 2, 3, 4, 5 ตามลำดับ ด้วยวิธีการเดียวกัน ได้ผลดังแสดง

Output Layer

t = target (ค่าจริงที่ต้องการ) และ O = output (ผลการพยากรณ์จากแบบจำลอง)

$$(t-O) = -0.756$$

$$O(1-O) = 0.119$$

$$\Delta = (t - O)O(1 - O) = -0.090$$

คำนวณหาค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง Hidden node กับ Output (Weight change = $LR * \Delta * \text{Output from hidden node}$)

$$\text{Weight change ระหว่าง output กับ hidden node 1} = -0.0019$$

$$\text{Weight change ระหว่าง output กับ hidden node 2} = -0.0010$$

$$\text{Weight change ระหว่าง output กับ hidden node 3} = -0.0035$$

$$\text{Weight change ระหว่าง output กับ hidden node 4} = -0.0090$$

$$\text{Weight change ระหว่าง output กับ hidden node 5} = -0.0021$$

$$\text{Bias change (LR * } \Delta \text{)} = -0.0027$$

Hidden Layer

O = Output จาก hidden node

Hidden node 1

Input node ต่างๆ ไปยัง Hidden node 1

$$\text{Weight change ระหว่าง input 1 กับ hidden node 1} = 0.000008$$

$$\text{Weight change ระหว่าง input 2 กับ hidden node 1} = 0.000080$$

$$\text{Weight change ระหว่าง input 3 กับ hidden node 1} = 0.000007$$

$$\text{Weight change ระหว่าง input 4 กับ hidden node 1} = 0.000008$$

$$\text{Weight change ระหว่าง input 5 กับ hidden node 1} = 0.000009$$

$$\text{Bias change (LR * } \Delta \text{)} = 0.000084$$

Hidden node 2

Input node ต่างๆ ไปยัง Hidden node 2

$$\text{Weight change ระหว่าง input 1 กับ hidden node 2} = -0.000022$$

$$\text{Weight change ระหว่าง input 2 กับ hidden node 2} = -0.000213$$

$$\text{Weight change ระหว่าง input 3 กับ hidden node 2} = -0.000019$$

$$\text{Weight change ระหว่าง input 4 กับ hidden node 2} = -0.000022$$

$$\text{Weight change ระหว่าง input 5 กับ hidden node 2} = -0.000213$$

$$\text{Bias change (LR * } \Delta \text{)} = -0.000224$$

Hidden node 3

Input node ต่างๆ ไปยัง Hidden node 3

Weight change ระหว่าง input 1 กับ hidden node 3 = 0.000007

Weight change ระหว่าง input 2 กับ hidden node 3 = 0.000073

Weight change ระหว่าง input 3 กับ hidden node 3 = 0.000006

Weight change ระหว่าง input 4 กับ hidden node 3 = 0.000007

Weight change ระหว่าง input 5 กับ hidden node 3 = 0.000008

Bias change (LR * delta) = 0.000076

Hidden node 4

Input node ต่างๆ ไปยัง Hidden node 4

Weight change ระหว่าง input 1 กับ hidden node 4 = -0.000058

Weight change ระหว่าง input 2 กับ hidden node 4 = -0.000569

Weight change ระหว่าง input 3 กับ hidden node 4 = -0.000050

Weight change ระหว่าง input 4 กับ hidden node 4 = -0.000058

Weight change ระหว่าง input 5 กับ hidden node 4 = -0.000061

Bias change (LR * delta) = -0.000599

Hidden node 5

Input node ต่างๆ ไปยัง Hidden node 5

Weight change ระหว่าง input 1 กับ hidden node 5 = -0.000104

Weight change ระหว่าง input 2 กับ hidden node 5 = -0.001024

Weight change ระหว่าง input 3 กับ hidden node 5 = -0.000090

Weight change ระหว่าง input 4 กับ hidden node 5 = -0.000105

Weight change ระหว่าง input 5 กับ hidden node 5 = -0.000110

Bias change (LR * delta) = -0.001078

รวมค่าปรับแก้สำหรับค่าถ่วงน้ำหนัก ระหว่าง Output กับ Hidden layer

ค่าปรับแก้ระหว่าง output กับ hidden node 1

$$= (-0.001114)+(-0.001307)+(-0.001292)+(-0.000411)+(-0.0019) = -0.006024$$

ค่าปรับแก้ระหว่าง output กับ hidden node 2

$$= (-0.001460)+(-0.001012)+(-0.001141)+(-0.001769)+(-0.0010) = -0.006423$$

ค่าปรับแก้ระหว่าง output กับ hidden node 3

$$= (-0.001000)+(-0.000170)+(-0.000930)+(-0.001300)+(-0.00030) = -0.003852$$

ค่าปรับแก้ระหว่าง output กับ hidden node 4

$$= (-0.001636)+(-0.001373)+(-0.001649)+(-0.001333)+(-0.00080) = -0.006768$$

ค่าปรับแก้ระหว่าง output กับ hidden node 5

$$= (-0.002501)+(-0.001804)+(-0.001782)+(-0.001614)+(-0.00200) = -0.008912$$

ค่าปรับแก้ bias

$$= (-0.002501)+(-0.002587)+(-0.002732)+(-0.002042)+(-0.00270) = -0.012563$$

รวมค่าปรับแก้สำหรับค่าถ่วงน้ำหนัก ระหว่าง Hidden layer กับ Input layer

Hidden node 1

ค่าปรับแก้ระหว่าง hidden node 1 กับ input node 1

$$= (0.000029)+(0.000005)+(0.000007)+(0.000047)+(0.000008) = 0.000096$$

ค่าปรับแก้ระหว่าง hidden node 1 กับ input node 2

$$= (0.000005)+(0.000003)+(0.000005)+(0.000003)+(0.000008) = 0.000124$$

ค่าปรับแก้ระหว่าง hidden node 1 กับ input node 3

$$= (0.000015)+(0.000014)+(0.000010)+(0.000005)+(0.000007) = 0.000051$$

ค่าปรับแก้ระหว่าง hidden node 1 กับ input node 4

$$= (0.000022)+(0.000016)+(0.000014)+(0.000005)+(0.000008) = 0.000066$$

ค่าปรับแก้ระหว่าง hidden node 1 กับ input node 5

$$= (0.000005)+(0.000024)+(0.000017)+(0.000007)+(0.000009) = 0.000061$$

Hidden node 2

ค่าปรับแก้ระหว่าง hidden node 2 กับ input node 1 = -0.000193

ค่าปรับแก้ระหว่าง hidden node 2 กับ input node 2 = -0.000308

ค่าปรับแก้ระหว่าง hidden node 2 กับ input node 3 = -0.000115

ค่าปรับแก้ระหว่าง hidden node 2 กับ input node 4 = -0.000150

ค่าปรับแก้ระหว่าง hidden node 2 กับ input node 5 = -0.000327

Hidden node 3

ค่าปรับแก้ระหว่าง hidden node 3 กับ input node 1 = 0.000173

ค่าปรับแก้ระหว่าง hidden node 3 กับ input node 2 = 0.000108

ค่าปรับแก้ระหว่าง hidden node 3 กับ input node 3 = 0.000063

ค่าปรับแก้ระหว่าง hidden node 3 กับ input node 4 = 0.000083

ค่าปรับแก้ระหว่าง hidden node 3 กับ input node 5 = 0.000067

Hidden node 4

ค่าปรับแก้ระหว่าง hidden node 4 กับ input node 1 = -0.000760

ค่าปรับแก้ระหว่าง hidden node 4 กับ input node 2 = -0.000864

ค่าปรับแก้ระหว่าง hidden node 4 กับ input node 3 = -0.000349

ค่าปรับแก้ระหว่าง hidden node 4 กับ input node 4 = -0.000447

ค่าปรับแก้ระหว่าง hidden node 4 กับ input node 5 = -0.000424

Hidden node 5

ค่าปรับแก้ระหว่าง hidden node 5 กับ input node 1 = -0.001381

ค่าปรับแก้ระหว่าง hidden node 5 กับ input node 2 = -0.001593

ค่าปรับแก้ระหว่าง hidden node 5 กับ input node 3 = -0.000686

ค่าปรับแก้ระหว่าง hidden node 5 กับ input node 4 = -0.000887

ค่าปรับแก้ระหว่าง hidden node 5 กับ input node 5 = -0.000816

ค่าปรับแก้ระหว่าง bias ระหว่าง hidden node กับ input node ต่างๆ

Hidden node 1

$$= (0.000093)+(0.000097)+(0.000102)+(0.000049)+(0.000084) = 0.000426$$

Hidden node 2

$$= (-0.000213)+(-0.000216)+(-0.000233)+(-0.000083)+(-0.0002) = -0.000968$$

Hidden node 3

$$= (0.000151)+(0.000040)+(0.000154)+(0.000112)+(0.000076) = 0.000533$$

Hidden node 4

$$= (-0.000597)+(-0.000644)+(-0.000654)+(-0.000463)+(-0.0005) = -0.002958$$

Hidden node 5

$$= (-0.001274)+(-0.001229)+(-0.001395)+(-0.000762)+(-0.0010) = -0.005737$$

จากนั้นให้ปรับค่าถ่วงน้ำหนักใหม่ทั้งหมด จากสูตร

ค่าถ่วงน้ำหนัก (ใหม่) = ค่าถ่วงน้ำหนัก (เดิม) + ค่าปรับแก้ค่าถ่วงน้ำหนัก

ได้ผลแสดงดังตารางที่ 3-4

ตารางที่ 3-4 ค่าถ่วงน้ำหนักที่ปรับแก้ใหม่

ไฮประสาท จาก	Hidden 1					
	Node 1	node 2	node 3	node 4	node 5	Output
Input 1	-1.499904	2.499807	1.500173	0.219240	0.778619	
Input 2	1.000124	-0.230308	-1.499892	-1.270864	0.648407	
Input 3	0.150051	0.119885	2.400063	1.499651	-0.550686	
Input 4	0.250066	0.249850	-2.399917	-1.230447	-0.450887	
Input 5	-2.139939	-0.220327	0.120067	0.119576	0.999184	
Hidden 1						$(-0.15-0.006024)$ $= -0.156024$
Hidden 2						0.343577
Hidden 3						-0.253852
Hidden 4						0.993232
Hidden 5						2.241088
	Node 1	node 2	node 3	node 4	node 5	Output
Bias	0.240426	-0.500968	-0.599467	0.467042	0.494263	-0.242563

จากนั้นจึงเริ่มต้นคำนวณเดินหน้า (Forward pass) ด้วย Iteration ที่ 2 ด้วยวิธีการเดียวกันแต่ใช้ค่าถ่วงน้ำหนักใหม่ที่ได้ จากตารางที่ 3-4

จากนั้นให้คำนวณไปข้างหน้าตามวิธีการเดิม จนกระทั่งได้ค่า RMSE < 0.05 จึงหยุดคำนวณที่ Iteration ที่ 3965 ดังแสดงในตารางที่ 3-5

ตารางที่ 3-5 ค่า Root Mean Square Error (RMSE) ที่ Iteration ต่างๆ

Iteration	RMSE
1	0.769303
2	0.764444
3	..
3965	0.029057

และได้ค่าถ่วงน้ำหนัก (ตารางที่ 3-6) ที่เหมาะสมจะถูกเก็บค่าไว้แล้วนำไปใช้ในการทดสอบแบบจำลองในช่วง Testing ต่อไป

ตารางที่ 3-6 ค่าถ่วงน้ำหนักสุดท้ายที่ได้จากการคำนวณ

ไฮประสาท จาก	Hidden 1					Output
	node 1	node 2	node 3	node 4	node 5	
Input 1	-1.451575	2.459980	1.504622	0.315075	0.781086	
Input 2	0.596431	-0.120780	-1.508202	-1.124514	0.555930	
Input 3	1.744225	-0.635021	2.108286	0.633609	-1.184651	
Input 4	1.566361	-0.390834	-2.650306	-1.983127	-0.936911	
Input 5	-2.832249	0.048464	0.168912	0.462883	1.016992	
Hidden 1						4.237854
Hidden 2						-1.354043
Hidden 3						-0.530690
Hidden 4						-1.557943
Hidden 5						-1.586240
	node 1	node 2	node 3	node 4	node 5	Output
Bias	-0.366664	-0.400239	-0.646661	0.695066	0.420240	0.502022

ภาคผนวก

ภาคผนวก ก
การตรวจสอบประสิทธิภาพของการพยากรณ์

ในการตรวจสอบความถูกต้องและประสิทธิภาพของแบบจำลอง จะต้องมีการเปรียบเทียบระหว่างปริมาณน้ำที่ได้จากการคำนวณด้วยแบบจำลอง ANN กับข้อมูลที่ได้จากการตรวจวัดจริงในสนาม ในทางปฏิบัตินิยมใช้ตัวแปรทางสถิติจำนวน 3 ตัวแปร มาใช้เป็นเกณฑ์ในการประเมินประสิทธิผลของพารามิเตอร์ต่าง ๆ ของแบบจำลอง ดังนี้

ตัวแปรทางสถิติ	สมการ
สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient, r)	$r = \frac{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m) \times (Q_{ci} - \bar{Q}_c)}{\sqrt{\left[\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2 \times \sum_{i=1}^N (Q_{ci} - \bar{Q}_c)^2 \right]}}$ (ก-1)
Root Mean Square Error (RMSE)	$RMSE = \left(\frac{\sum_{i=1}^N (Q_{mi} - Q_{ci})^2}{N} \right)^{0.5}$ (ก-2)
Efficiency Index (EI)	$EI = \frac{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2 - \sum_{i=1}^N (Q_{mi} - Q_{ci})^2}{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2} \times 100\%$ (ก-3)

เมื่อ	Q_{mi}	= อัตราการไหลที่ได้จากการตรวจวัดที่เวลา i
	$\bar{Q}_m$	= ค่าเฉลี่ยของอัตราการไหลที่ได้จากการตรวจวัด
	Q_{ci}	= อัตราการไหลที่ได้จากแบบจำลองที่เวลา i
	$\bar{Q}_c$	= ค่าเฉลี่ยของอัตราการไหลที่ได้จากแบบจำลอง
	N	= จำนวนของข้อมูล

สำหรับรายละเอียดของตัวแปรทางสถิติแต่ละตัวแปร แสดงได้ดังนี้

สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient, r) โดยปกติแล้วค่าสัมประสิทธิ์สหสัมพันธ์ (r) มีค่าอยู่ระหว่าง -1 ถึง 1 ถ้า r มีค่าเข้าใกล้ 1 แสดงว่าข้อมูลที่คำนวณได้และที่ตรวจวัดได้จากภาคสนามมีความสัมพันธ์แบบปฏิกิริยาโดยตรงที่ดี แต่เมื่อไรก็ตามที่ r มีค่าเข้าใกล้ 0 แสดงว่าข้อมูลทั้ง

สองมีความสัมพันธ์กันน้อยหรือแทบไม่มีเลย โดยทั่วไปแล้วในการศึกษาด้านอุทกวิทยาและชลศาสตร์ ค่า r ควรมีค่ามากกว่า 0.7 จึงจะถือว่าข้อมูลทั้งสองมีความสัมพันธ์กันอยู่ในเกณฑ์ที่ยอมรับได้

Root Mean Square Error (RMSE) เป็นตัวแปรทางสถิติที่แสดงความคลาดเคลื่อนสมบูรณ์ (absolute error) ระหว่างข้อมูลที่ได้จากการคำนวณด้วยแบบจำลองและข้อมูลที่ได้จากการตรวจวัด ในกรณีที่ค่าเข้าใกล้ศูนย์แสดงว่ามีความสัมพันธ์ที่ดีมาก

Efficiency Index (EI) เป็นตัวแปรทางสถิติที่แสดงระดับความสัมพันธ์ (degree of association) ระหว่างข้อมูลที่ได้จากการคำนวณด้วยแบบจำลองและข้อมูลที่ได้จากการตรวจวัด ถ้ามีค่าเท่ากับ 100% แสดงว่าผลการวิเคราะห์ที่ได้จากแบบจำลองมีค่าเท่ากับปริมาณน้ำท่าที่ได้จากการตรวจวัดทุกข้อมูล โดยทั่วไปแล้วในการศึกษาด้านอุทกวิทยาและชลศาสตร์ ค่า EI ควรมีค่ามากกว่า 70% จึงจะถือว่าข้อมูลทั้งสองมีความสัมพันธ์กันอยู่ในเกณฑ์ที่ยอมรับได้

ตัวอย่างแสดงการคำนวณ

No	Obs. (Q_m)	Model (Q_c)	$Q_{mi} - \bar{Q}_m$	$Q_{ci} - \bar{Q}_c$	(4x5)	$(Q_{mi} - \bar{Q}_m)^2$	$(Q_{ci} - \bar{Q}_c)^2$	$(Q_{mi} - Q_{ci})^2$
1	2	3	4	5	6	7	8	9
1	2	5	-4.0	-0.6	2.4	16.0	0.36	9.0
2	4	6	-2.0	0.4	-0.8	4.0	0.16	4.0
3	6	6	0.0	0.4	0.0	0.0	0.16	0.0
4	8	5	2.0	-0.6	-1.2	4.0	0.36	9.0
5	10	6	4.0	0.4	1.6	16.0	0.16	16.0
Total	30	28			2.0	40.0	1.2	38.0
Avg.	6	5.6						

$$\sum_{i=1}^N [(Q_{mi} - \bar{Q}_m) \times (Q_{ci} - \bar{Q}_c)] = (\text{ช่อง 6}) = 2.0$$

$$\sqrt{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2 \times (Q_{ci} - \bar{Q}_c)^2} = 6.928$$

$$r = \frac{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m) \times (Q_{ci} - \bar{Q}_c)}{\sqrt{\left[\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2 \times \sum_{i=1}^N (Q_{ci} - \bar{Q}_c)^2 \right]}}$$

$$= 2/6.928 = 0.289$$

$$RMSE = \left(\frac{\sum_{i=1}^N (Q_{mi} - Q_{ci})^2}{N} \right)^{0.5}$$

$$= \text{SQRT}(\text{ช่อง } 9 / \text{จำนวนวัน}) = \text{SQRT}(38/5) = 2.757$$

$$EI = \frac{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2 - \sum_{i=1}^N (Q_{mi} - Q_{ci})^2}{\sum_{i=1}^N (Q_{mi} - \bar{Q}_m)^2} \times 100\%$$


$$= ((\text{ช่อง } 7 - \text{ช่อง } 9) / \text{ช่อง } 7) * 100 = 0.05 * 100 = 5 \%$$

ผลการตรวจสอบประสิทธิภาพการพยากรณ์ในกรณีต่างๆ

กรณีที่ 1 พยากรณ์ไม่แม่นยำ แต่มีทิศทางเดียวกัน

Day	Runoff - cms.	
	Observe	Model
1	2	4
2	4	6
3	6	8
4	8	10
5	10	12


$$r = 1.00, \text{ RMSE} = 2.0, \text{ EI} = 0.5$$



กรณีที่ 2 พยากรณ์ค่อนข้างแม่นยำ และมีทิศทางเดียวกัน

Day	Runoff - cms.	
	Observe	Model
1	2	3
2	4	5
3	6	7
4	8	9
5	10	11


$$r = 1.00, \text{ RMSE} = 1.0, \text{ EI} = 0.875$$



กรณีที่ 3 พยากรณ์ไม่แม่นยำ และคนละทิศทาง

Day	Runoff - cms.	
	Observe	Model
1	2	5
2	4	6
3	6	6
4	8	5
5	10	6


$r = 0.289$, $RMSE = 2.76$, $EI = 0.05$



กรณีที่ 4 พยากรณ์ค่อนข้างแม่นยำ และมีทิศทางเดียวกัน (แบบไม่เป็นเส้นตรง)

Day	Runoff - cms.	
	Observe	Model
1	2	2.5
2	4	4.5
3	6	6.5
4	5	4.5
5	4	3.5

$r = 0.932$, $RMSE = 0.5$, $EI = 0.95$



ภาคผนวก ข

การใช้แบบจำลอง ANN ในการพยากรณ์ปริมาณน้ำ

www.themegallery.com

การใช้แบบจำลอง ANNs (WINN 97)

ในการพยากรณ์ปริมาณน้ำต้นทุน

Artificial Neural Network


วัชร เลือดี ป.การชลประทาน/ วศบ. โยธา/ นบ.

วศม. ชลประทาน/ D. Eng. (IWRM)

สถาบันพัฒนาการชลประทาน กรมชลประทาน

โทร 0812340951 Email wachara@irricollege.ac.th

Forward Pass
For Pattern 1




Training and Testing Period

ช่วง Training			ช่วง Testing		พยากรณ์ รายวันต่อ
ปีที่ 1 ตุลาคม 1 ก.ค. – 30 พ.ย. 95 รวม 153 วัน	ปีที่ 2 ตุลาคม 1 ก.ค. – 30 พ.ย. 96 รวม 153 วัน	ปีที่ 3 ตุลาคม 1 ก.ค. – 30 พ.ย. 01 รวม 153 วัน	ปีที่ 1 ตุลาคม 1 ก.ค. – 30 พ.ย. 99 รวม 153 วัน	ปีที่ 1 ตุลาคม 1 ก.ค. – 30 พ.ย. 00 รวม 153 วัน	
459 วัน			306 วัน		

Microsoft Excel - TrainingTesting.xls

Cordia N ไม้พริก 14 B I U % 100%

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	Training	Input				Output	Period						
2	Pattern	SKI _T	QN _T	RN _{T-1}	RSK _T	SKI _{T-1}	Date		Training Period				
3	1	167.82	254.00	9.30	0.00	207.18	1/7/1995		1 July - 30 November 1995, 1996 และ 2001				
4	2	207.18	120.80	0.70	0.50	132.06	2/7/1995		รวม 459 Patterns				
5	3	132.06	69.50	3.60	2.00	115.86	3/7/1995						
6	4	115.86	54.60	28.20	4.60	103.70	4/7/1995						
7	5	103.70	73.40	14.20	0.80	256.13	5/7/1995						
8	6	256.13	99.20	0.00	1.30	207.29	6/7/1995						
9	7	207.29	201.80	0.70	2.30	219.68	7/7/1995						
10	8	219.68	316.00	0.00	1.10	273.61	8/7/1995						
11	9	273.61	266.00	5.00	3.00	510.88	9/7/1995						
12	10	510.88	819.00	57.90	4.30	676.39	10/7/1995						
13	11	676.39	547.60	0.00	13.60	493.40	11/7/1995						
14	12	493.40	276.00	0.00	0.00	311.81	12/7/1995						
15	13	311.81	180.20	0.00	2.80	286.11	13/7/1995						

รูปวาด: รูปร่างอัตโนมัติ

ปุ่ม: Start, Mic..., Mic..., 11..., Thai..., Gra..., Eval..., EN, 11:05

การประยุกต์ใช้งานพยากรณ์ปริมาณน้ำไหลลงอ่างฯ

1. เปิด File Excel ใน Folder d:\ANN\data\TrainingTesting1.xls
2. เปิดโปรแกรม WinNN
3. แก้ไขค่า Parameters ตามรูป

WinNN - [Neural Control Panel]

File Edit Data View Plot Setup... Window Help

New Net

Training Results

RMS Error: 0
Change: 0
Iterations: 0
Good Pats.: 0 %
Target Err: 0.05

Net Size

Layers: 3
Layer Size: 4
Neuron func: Sigmoid

Learning Parameters

Eta: 0.01
Alpha: 0.5
Input Noise: 0
Weight Noise: 0
Temp: 1
Iter./calc: 5
Clip Patterns: 0

Weights

Min: -3
Max: 3
Total Number: 31
Min: -2.7997E+0
Max: 2.9897E+0

Epoch Parameters

Epoch length: 1
Random Sampling: ☐

Files


Patterns: Click here to Open File
Weight: Click here to Open File
Test File: Click here to Open File

Target Err. 0.05


Layer Size 4 5 1

Eta = 0.01


4. ไป Excel ที่ Sheet Training, Copy ข้อมูลทั้งหมด 459 วัน
5. ไป WINNN, Menu Edit, Paste Pats (linked)
6. ไป Excel ที่ Sheet Testing, Copy ข้อมูลทั้งหมด 306 วัน
7. ไป WINNN, Menu Edit, Paste Tst Pats (linked)
8. ข้อมูลที่จะใช้ Train และ Test โครงข่ายประสาทถูก
นำเข้าโปรแกรมแล้ว



9. ทำการ Normalize ข้อมูลให้อยู่ในช่วง 0.05-0.95 โดยไปที่
WINN, Menu, Data, Normalize





10. ทำการ Train และ Test ข้อมูลด้วย WINN โดยกดปุ่ม และกด
ปุ่มกราฟ (ปุ่มกราฟ)
11. จะสังเกตเห็นเส้นกราฟพยากรณ์วิ่งเข้าใกล้ค่าจริง



12. โดยปกติโปรแกรมจะหยุดทำงานเมื่อค่าแตกต่างระหว่างการพยากรณ์กับค่าจริงไม่เกิน 0.05 แต่เราจะกด Stop เมื่อโปรแกรมวิ่งไปกลับได้ 10,000 iterations เพื่อประหยัดเวลา
13. ทำการตรวจสอบความแม่นยำ และประสิทธิภาพของแบบจำลอง จากค่าตัวแปร R, EI และ RMSE
14. เมื่อได้ผลเป็นที่พอใจแล้ว ก็สามารถที่จะนำไปใช้ในการพยากรณ์ต่อไปได้
15. ทดลองนำแบบจำลองที่ฝึกแล้วไปใช้พยากรณ์ปริมาณน้ำไหลเข้าอ่างวันพรุ่งนี้ โดยให้สมมุติว่ามีเหตุการณ์เกิดขึ้นจริงในวันนี้ใน Excel ดังนี้

SKI_T	$QN1_T$	RN_{T-1}	RSK_T	SKI_{T+1}
167.82	254.00	9.30	0.00	1
ผลลัพธ์ -->				297.967
ค่าจริง -->				207.18

(ใส่ 1 ไว้ก่อน แล้ว copy ทั้งหมด ไป paste Tst Pats)
(Copy Tst Outputs ก็จะได้ผลลัพธ์ เอามาแทนเลข 1)



ภาคผนวก ค
บทที่ 3
วิธีการดำเนินการวิจัย

3.1 การประยุกต์ใช้ Artificial Neural Networks สำหรับการพยากรณ์ปริมาณน้ำ

มีวัตถุประสงค์เพื่อจะศึกษาการทำงานของแบบจำลองโครงข่ายประสาทเทียม Artificial Neural Networks (ANNs) ในการพยากรณ์น้ำล้นหน้า 1 วัน โดยใช้วิธี Back Propagation ซึ่งจะนำมาประยุกต์ใช้กับข้อมูลปริมาณการไหลรายวัน ณ จุดออกของกลุ่มน้ำคลองท่าตะเภา ที่สถานีเทศบาล2 (X.180) จ.ชุมพร

3.1.1 ข้อมูลที่ใช้ในการศึกษา

1) ข้อมูลปริมาณน้ำท่ารายวันจากสถานีวัดน้ำท่าของกรมชลประทาน ที่อยู่ในพื้นที่ลุ่มน้ำคลองท่าตะเภา จ.ชุมพร จำนวน 3 สถานี ได้แก่ สถานีวัดน้ำคลองท่าที่บ้านท่าแซะ (X.64), สถานีคลองท่าตะเภาที่บ้านวังครก (X.158) และ สถานีคลองท่าตะเภาที่ตำบลตากแดด หรือสถานีเทศบาล2 (X.180) ช่วงปี 2003 - 2007

2) ข้อมูลปริมาณน้ำฝนรายวันในพื้นที่ลุ่มน้ำคลองท่าตะเภา ได้แก่ สถานี อ.ท่าแซะ (11091) และสถานีบ้านวังครก (10310) ช่วงปี ช่วงปี 2003 - 2007

แสดงตำแหน่งสถานีตรวจวัดข้อมูลต่าง ๆ ไว้ในรูปที่ 3.1.1-1 และแสดงกราฟได้ในรูปที่ 3.1.1-2


3.1.2 ขั้นตอนในการพัฒนาแบบจำลอง

1) คัดเลือกปีที่จะทำการฝึกและทดสอบแบบจำลอง (Training and Testing period) เนื่องจาก ANNs Model เป็นแบบจำลองกล่องดำ (Black Box Model) ซึ่งเน้นความสัมพันธ์ระหว่าง Input และ Output เป็นสำคัญ โดยไม่เน้นทางด้านกายภาพมากนัก ดังนั้นจึงต้องพิจารณาเลือกใช้ข้อมูลที่มีความสัมพันธ์กัน โดยมีหลักเกณฑ์ที่ว่า ในช่วงของการฝึกหัดแบบจำลอง จะคัดเลือกปีที่ครอบคลุมปริมาณน้ำสูงสุด เพื่อให้แบบจำลองได้เรียนรู้ขีดจำกัดของข้อมูล ส่วนปีที่ใช้ในการทดสอบนั้น จะเลือกปีที่ไม่ใกล้เคียงปีปัจจุบัน สรุปช่วงเวลาที่ใช้ในการฝึกหัดและทดสอบแบบจำลองได้ดังนี้


- ช่วงการฝึกแบบจำลอง (Training period) ใช้ช่วงฤดูฝนปี 2003, 2004 และ 2006

- ช่วงการทดสอบแบบจำลอง (Testing period) ใช้ช่วงฤดูฝนปี 2005 และ 2007

ค่าสัมประสิทธิ์ความสัมพันธ์ระหว่างข้อมูลที่สถานีต่าง ๆ กับข้อมูล ณ ตำแหน่งพิจารณา ซึ่งได้แก่ สถานี X.180 ที่เวลา $t+1$ ทั้งในช่วงการฝึกและทดสอบแบบจำลอง แสดงได้ดังตารางที่ 3.1.1-1



รูปที่ 3.1.1-1 ที่ตั้งสถานีตรวจวัดข้อมูลน้ำฝนและน้ำท่าในลุ่มน้ำท่าตะเภา



รูปที่ 3.1.1-2 สถิติข้อมูลน้ำฝนและน้ำท่าที่จะใช้นำเข้าแบบจำลอง ANNs ระหว่างปี 2003 – 2007

ตารางที่ 3.1.1-1 ค่าสัมประสิทธิ์สหสัมพันธ์ (r) ระหว่างปริมาณการไหลของสถานี X.180 ที่เวลาช่วงหน้า 1 วัน และ 2 วัน กับปริมาณน้ำฝนและปริมาณน้ำท่าของแต่ละสถานี

ความสัมพันธ์ระหว่าง X.180 กับสถานีต่าง ๆ	X.180(t+1)		X.180(t+2)	
	Training	Testing	Training	Testing
X.180(t)	0.92	0.90	0.80	0.76
X.158(t)	0.77	0.74	0.66	0.60
X.64(t)	0.80	0.78	0.70	0.64
10191(t)	0.31	0.51	0.41	0.63
10310(t)	0.38	0.51	0.47	0.64

หมายเหตุ : t+1 หมายถึง ข้อมูลที่เวลาช่วงหน้า 1 วัน

t+2 หมายถึง ข้อมูลที่เวลาช่วงหน้า 2 วัน

3.1.3 การศึกษาความสัมพันธ์ของแบบจำลอง

จากข้อกำหนดในการศึกษาการพยากรณ์ปริมาณการไหลของสถานีวัดน้ำท่า X.180 ที่สะพานเทศบาล2 ช่วงหน้า 1 วัน และ 2 วัน โดยใช้ข้อมูลทั้งจากปริมาณน้ำท่าจากสถานีวัดน้ำท่าและข้อมูลฝนจากสถานีวัดน้ำฝนภายในพื้นที่ลุ่มน้ำท่าตะเภา สามารถนำมาจัดทำเป็นฟังก์ชันของความสัมพันธ์ระหว่างข้อมูลได้ดังนี้

$$Q_{t+1,2}(X.180) = f(Q_t(X.180), Q_t(X.158), Q_t(X.64), R_{t10191}, R_{t10311}) \quad (3-1)$$

เมื่อ	f	หมายถึง ความสัมพันธ์แบบไม่เป็นเส้นตรง
	$Q_t(X.180)$	หมายถึง ปริมาณน้ำสะพานเทศบาล2 วันปัจจุบัน, ลบ.ม./วินาที
	$Q_t(X.158)$	หมายถึง ปริมาณน้ำบ้านวังครก วันปัจจุบัน, ลบ.ม./วินาที
	$Q_t(X.64)$	หมายถึง ปริมาณน้ำคลองท่าชะ วันปัจจุบัน, ลบ.ม./วินาที
	R_{t10191}	หมายถึง สถานีน้ำฝน อ.ท่าชะ วันปัจจุบัน, มม.
	R_{t10311}	หมายถึง สถานีน้ำฝนบ้านวังครก วันปัจจุบัน, มม.
	$Q_{t+1,2}(X.180)$	หมายถึง ปริมาณน้ำสะพานเทศบาล 2 ล่วงหน้า 1 วัน และ 2 วัน, ลบ.ม./วินาที

3.1.4 แนวทางการศึกษาแบบจำลอง

ทำการกำหนดโครงสร้างของแบบจำลอง ANNs เป็นลักษณะ 3 Layers ได้แก่ Input, Hidden และ Output Layer ซึ่งอธิบายความหมายของแต่ละ Layer ได้ดังนี้

1) Input Layer หรือ ข้อมูลนำเข้า ได้แก่ ข้อมูลปริมาณน้ำท่าที่สถานี X.180, X.158, X.64 ปริมาณฝนที่ อ.ท่าชะ (10191) และ บ้านวังครก (10311) ซึ่ง Layer นี้จะมีค่าคงที่ เท่ากับ 5

2) Hidden Layer จะเป็น Layer ที่จะต้องทำการสุ่มเปลี่ยนค่า กำหนดไว้ตั้งแต่ 1 ถึง 5

3) Output Layer หรือ ผลการพยากรณ์ ได้แก่ ปริมาณน้ำท่าที่สถานี X.180 ล่วงหน้า 1 วัน ซึ่ง Layer นี้จะมีค่าคงที่เท่ากับ 1 เสมอ

4) ใช้แนวทางการดำเนินงานดังกล่าว กับการพยากรณ์ปริมาณน้ำล่วงหน้า 2 วัน

ซึ่งจากการกำหนดดังกล่าว การศึกษาในครั้งนี้จะทำการฝึกแบบจำลองด้วยกันทั้งหมด 5 รูปแบบ คือ 5-1-1, 5-2-1, 5-3-1, 5-4-1 และ 5-5-1 เพื่อหาแนวโน้มในการพยากรณ์ปริมาณการไหลของน้ำที่ดีที่สุดต่อไป

บทที่ 4

ผลการวิจัยและการวิเคราะห์วิจารณ์

4.1 ผลการประยุกต์ใช้แบบจำลอง ANNs สำหรับการพยากรณ์น้ำล้นวงหน้า

4.1.1 ขั้นตอนการฝึกแบบจำลอง

1) ข้อมูลที่ใช้ในช่วงของการฝึกแบบจำลอง (Training period) ได้แก่ ข้อมูลอัตราการไหลของน้ำท่าสถานี X.180, X.158, X.64 และข้อมูลฝนของสถานี 10191 และ 10311 ในช่วงฤดูฝน (เดือนก.ค. - พ.ย.) ปี 2003, 2004 และ 2006

2) โครงสร้างของแบบจำลองที่จะทำการตรวจสอบหาผลการพยากรณ์ที่ดีที่สุดในช่วงของการฝึกแบบจำลอง ได้แก่ รูปแบบ 5-1-1, 5-2-1, 5-3-1, 5-4-1 และ 5-5-1 (Input, Hidden, Output)

3) เมื่อได้รูปแบบโครงสร้างที่เหมาะสมแล้ว ต่อจากนั้น จะทำการปรับแก้ค่าพารามิเตอร์ ซึ่งพารามิเตอร์หลักที่จะต้องทำการปรับแก้ ได้แก่ Learning Rate และ Momentum Rate โดยที่ค่า Learning Rate (LR) จะมีผลต่อการเปลี่ยนแปลงค่าถ่วงน้ำหนักของ Node ถ้าค่าสูงจะทำให้การคำนวณแบบจำลองเร็วขึ้น แต่ถ้าสูงมากเกินไปจะเกิดการแกว่งของความแตกต่างระหว่างค่าพยากรณ์กับค่าตรวจวัดจริง สำหรับค่า Momentum Rate (MR) จะใช้แก้ปัญหาการแกว่งของความแตกต่างระหว่างค่าพยากรณ์กับค่าตรวจวัดจริงดังกล่าว

จะใช้วิธีการปรับแก้เพื่อค่า LR ซึ่งจะอยู่ระหว่าง 0.01-1.0 และค่า MR ระหว่าง 0-1 ซึ่งจะทำให้การเพิ่มค่าของทั้ง 2 พารามิเตอร์ทีละ 0.1 เท่า ๆ กัน คือ 0.13, 0.14, 0.15, 0.16 และ 0.17 ไปตามลำดับ เพื่อหาผลการพยากรณ์ที่ดีที่สุด

4) สำหรับค่าพารามิเตอร์อื่น ๆ กำหนดให้ใช้ค่าดังต่อไปนี้

(1) Target Error เป็นค่าของความผิดพลาดที่ยอมรับได้ของข้อมูล Input และ Output ยิ่งมีค่าน้อย จะทำให้ Output ที่ได้มีความถูกต้องมากขึ้น แต่ก็ทำให้ใช้เวลาในการคำนวณนานขึ้น ในที่นี้เลือกใช้เท่ากับ 0.05

(2) Transfer function เลือกใช้ Sigmoid function

(3) Input Noise = 0

(4) Weight Noise = 0


(5) Temp. = 1

(6) Iter./ Cal = 5


(7) Clip Patterns = 0

5) ทำการ Normalize ข้อมูลให้อยู่ในช่วง 0.05 - 0.95

แสดงหน้าต่างการนำเข้าข้อมูลของโปรแกรม WinNN97 ไว้ในรูปที่ 4.1.1-1 และหน้าต่างแสดงรูปแบบโครงสร้างของแบบจำลอง 5-5-1 ไว้ในรูป 4.1.1-2



รูปที่ 4.1.1-1 หน้าต่างการนำเข้าข้อมูลในโปรแกรม WinNN97



รูปที่ 4.1.1-2 แบบจำลองโครงสร้าง 5-5-1

4.1.2 ผลการฝึกแบบจำลอง


จากช่วงการฝึกแบบจำลอง หรือ Training period ตามโครงสร้างในรูปแบบต่าง ๆ และการปรับแก้พารามิเตอร์ที่สำคัญ สรุปได้ว่า รูปแบบโครงสร้างที่ให้ผลการพยากรณ์ที่ดีที่สุด ได้แก่ รูปแบบ 5-5-1 และค่าพารามิเตอร์ LR และ MR ทั้งสองค่าเท่ากับ 0.17 จะให้ผลการคำนวณที่ดีที่สุดเช่นกัน โดยมีค่าสัมประสิทธิ์ความถูกต้องต่าง ๆ ได้แก่ $r = 0.961$, $RMSE = 9.029$ ลบ.ม./วินาที และ $EI = 0.919$ ดังแสดงผลการฝึกแบบจำลองตามโครงสร้างต่าง ๆ ไว้ในตารางที่ 4.1.2-1 และผลการฝึกแบบจำลองจากการปรับแก้ค่าพารามิเตอร์ไว้ในตารางที่ 4.1.2-2 พร้อมทั้งแสดงผลการเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริงที่สถานี X.180 ในช่วงฝึกแบบจำลอง ไว้ในรูปที่ 4.1.2-1 ซึ่งจะได้้นำโครงสร้างและพารามิเตอร์ดังกล่าวไปใช้ในการทดสอบแบบจำลอง (Testing) ต่อไป

ตารางที่ 4.1.2-1 สรุปผลการฝึกแบบจำลองตามโครงสร้างรูปแบบต่าง ๆ

Input Layers	Hidden Layers	Output Layers	r	RMSE (cms)	EI
5	1	1	0.932	11.310	0.867
5	2	1	0.933	11.202	0.870
5	3	1	0.952	9.478	0.907
5	4	1	0.955	9.196	0.912
5	5	1	0.961	9.029	0.919

ตารางที่ 4.1.2-2 สรุปผลการฝึกแบบจำลองจากการปรับแก้ค่าพารามิเตอร์ต่าง ๆ


Input Layers	Hidden Layers	Output Layers	Learning Rate	Momentum Rate	r	RMSE (cms)	EI
5	5	1	0.13	0.13	0.924	9.150	0.913
5	5	1	0.14	0.14	0.956	9.544	0.926
5	5	1	0.15	0.15	0.962	9.586	0.926
5	5	1	0.16	0.16	0.961	9.884	0.921
5	5	1	0.17	0.17	0.961	9.029	0.919



รูปที่ 4.1.2-1 กราฟเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริง
ที่สถานี X.180 ในช่วงฝึกแบบจำลอง

4.1.3 ผลการทดสอบแบบจำลอง


ช่วงของการทดสอบแบบจำลอง หรือ Testing period จะใช้ข้อมูลเดียวกันกับการฝึกแบบจำลอง ได้แก่ ข้อมูลอัตราการไหลของน้ำท่าที่สถานี X.180, X.158, X.64 และข้อมูลฝนของสถานี 10191 และ 10311 ในช่วงฤดูฝน (เดือนก.ค. - พ.ย.) ปี 2005 และ 2007 และนำโครงสร้างในรูปแบบ 5-5-1 และ พารามิเตอร์ต่าง ๆ ที่ทำการปรับเทียบแล้วในช่วงของการฝึกแบบจำลองมาเป็นข้อมูลนำเข้า โดยคัดเลือกข้อมูลในช่วงฤดูฝนปี 2005 และ 2007 ผลการทดสอบการพยากรณ์น้ำล้นหน้า 1 วัน ที่สถานีวัดน้ำท่า สะพานเทศบาล2 ในเขตตัวเมืองจังหวัดชุมพร (X.180) ได้ผลออกมาเป็นที่น่าสนใจ ค่าสัมประสิทธิ์ ความถูกต้องต่าง ๆ มีดังนี้ $r = 0.928$, $RMSE = 13.02$ ลบ.ม./วินาที และ $EI = 0.848$ ดังแสดงผลการเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริงที่สถานี X.180 ในช่วงทดสอบแบบจำลอง ไว้ในรูปที่ 4.1.3-1




รูปที่ 4.1.3-1 กราฟเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริง
ที่สถานี X.180 ในช่วงทดสอบแบบจำลอง

4.1.4 ผลการพยากรณ์น้ำล่วงหน้า 2 วัน

สำหรับผลการพยากรณ์น้ำล่วงหน้า 2 วัน เพื่อทดสอบความสามารถในการพยากรณ์ของแบบจำลอง ANNs นั้น จะใช้แนวทางและโครงสร้างของแบบจำลองเช่นเดียวกันกับการพยากรณ์ล่วงหน้า 1 วัน ที่ได้ดำเนินการไปแล้ว ผลการศึกษาเลือกใช้ค่าพารามิเตอร์ที่ให้ประสิทธิภาพในการพยากรณ์ดีที่สุด ได้แก่ $LR = 0.2$ และ $MR = 0.5$ ซึ่งในช่วงการฝึกแบบจำลอง (Training Period) ได้ค่า $R = 0.74$, $RMSE = 7.03$ ลบ.ม./วินาที และ $E.I. = 0.94$ โดยมีค่าปริมาณการไหลสูงสุด = 220 ลบ.ม./วินาที และช่วงการทดสอบแบบจำลอง (Testing Period) ได้ค่า $R = 0.80$, $RMSE = 21.18$ ลบ.ม./วินาที และ $E.I. = 0.61$ โดยมีค่าปริมาณการไหลสูงสุด = 211 ลบ.ม./วินาที ดังแสดงในรูปแบบของกราฟแสดงผลการเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริงที่สถานี X.180 ล่วงหน้า 2 วัน ในช่วงของการฝึกแบบจำลองและช่วงการทดสอบแบบจำลองไว้ในรูปที่ 4.1.4-1 และ 4.1.4-2 ตามลำดับ



รูปที่ 4.1.4-1 กราฟเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริง
ที่สถานี X.180 ล่วงหน้า 2 วัน ในช่วงฝึกแบบจำลอง



รูปที่ 4.1.4-2 กราฟเปรียบเทียบอัตราการไหลของน้ำที่ได้จากแบบจำลองกับข้อมูลที่ตรวจวัดจริง
ที่สถานี X.180 ล่วงหน้า 2 วัน ในช่วงทดสอบแบบจำลอง

4.1.5 สรุปผลการประยุกต์ใช้แบบจำลอง ANNs ในการพยากรณ์น้ำล้นวงหน้า

การนำแบบจำลอง ANNs มาประยุกต์ใช้นั้นมีวัตถุประสงค์เพื่อให้เป็นแบบจำลองสำรองในกรณีที่ระบบโทรมาตรหรือแบบจำลอง MIKE 11 – GIS ไม่สามารถที่จะให้ผลการพยากรณ์ได้ไม่ว่าจะเกิดจากสาเหตุใดก็ตาม ซึ่งจากผลการวิจัยในการสร้างแบบจำลองในการพยากรณ์ปริมาณน้ำไหลออกจากลุ่มน้ำคลองท่าตะเภา โดยแบบจำลอง ANN ดังกล่าวเป็นแบบ Black Box Model นั้น สามารถอธิบายและวิจารณ์ผลการวิจัยได้ดังนี้

1) การพยากรณ์อัตราการไหลของน้ำ ผลจากการพยากรณ์ แบบ ANNs ที่ดีที่สุด คือ ล่วงหน้า 1 วัน เนื่องจากยิ่งพยากรณ์ล่วงหน้าไกลออกไป เช่น 2 วันล่วงหน้า จะมีอิทธิพลอื่นเข้ามามีผลต่อแบบจำลองทำให้ความแม่นยำในการพยากรณ์ลดลง

2) การประยุกต์ใช้แบบจำลอง ANNs จะต้องวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอิทธิพลต่อผลลัพธ์เป็นสำคัญ ดังนั้นจึงมีความเข้าใจตัวแปรแต่ละตัวในการเลือกข้อมูลนำเข้าต่างๆ

3) ในการสร้างแบบจำลองเพื่อให้ได้ผลพยากรณ์ที่ดีที่สุด การเลือกสถานีวัดน้ำฝน สถานีวัดน้ำท่าที่สำคัญและข้อมูลน้ำฝน น้ำท่า วันที่ย้อนหลัง มีผลต่อการพยากรณ์ปริมาณน้ำสถานีวัดน้ำฝนที่ใช้จำนวน 2 สถานี ได้แก่ 10191 และ 10310 สถานีวัดน้ำท่า ได้แก่ จำนวน 3 สถานี ได้แก่ X.64, X.158 และ X.180

4) เนื่องจากแบบจำลอง ANNs เป็นจำลองประเภท Black Box Model ซึ่งเน้นความสัมพันธ์ระหว่าง Input และ Output เป็นสำคัญ โดยไม่เน้นปัจจัยทางด้านกายภาพ ดังนั้นการเลือกใช้ข้อมูลที่มีความสัมพันธ์กันตามนัยสำคัญ จึงมีผลต่อความแม่นยำของการพยากรณ์

5) แบบจำลอง ANNs ต้องมีการลองผิดลองถูกเพื่อหาจำนวน Node ในชั้นซ่อน (Hidden Layers) รวมถึงการทดลองหาจำนวนชั้น Hidden Layers ที่เหมาะสม เพื่อให้ได้โครงสร้างที่เหมาะสมในการพยากรณ์ จำนวน Node ที่เหมาะสมคือ 5-5-1 จำนวนชั้นของ Hidden Layers ที่เหมาะสมคือ 5

6) เนื่องจากสภาพลำน้ำมีการเปลี่ยนแปลงไปจากเดิมอย่างรวดเร็ว โดยมีสาเหตุมาจากการตกตะกอน หรือการกัดเซาะของลำน้ำ ทำให้พฤติกรรมการเรียนรู้จากแบบจำลอง ANNs ต่างไปจากเดิม จำเป็นต้องนำข้อมูลใหม่มานำเข้าเพื่อปรับปรุงแบบจำลองเพื่อให้ได้ผลพยากรณ์ที่น่าพอใจ

จากการศึกษาดังกล่าว จะเห็นว่าแบบจำลองที่สร้างจาก ANNs ง่ายและสะดวกต่อการใช้งาน โดยใช้ข้อมูลนำเข้าไม่มาก แต่มีข้อจำกัดสำหรับการศึกษา คือ ถ้าสภาพลุ่มน้ำเปลี่ยนแปลงไปจากเดิมอย่างรวดเร็วจะทำให้แบบจำลองผลไม่แม่นยำ โดยทั่วไป จำเป็นต้องมีการปรับแบบจำลอง ANNs ทุกๆ 3-5 ปี